



UCAM

UNIVERSIDAD CATÓLICA
DE MURCIA

ESCUELA INTERNACIONAL DE DOCTORADO
Programa de Doctorado en Tecnologías de la Computación e
Ingeniería Ambiental

Simulación de procesos hidrológicos utilizando técnicas de
machine learning y modelos hidrológicos

Autor:

Patricia Jimeno Sáez

Directores:

Dr. D. Javier Senent Aparicio
Dr. D. David Pulido Velázquez

Murcia, junio de 2018



UCAM

UNIVERSIDAD CATÓLICA
DE MURCIA

ESCUELA INTERNACIONAL DE DOCTORADO
Programa de Doctorado Tecnologías de la Computación e
Ingeniería Ambiental

Simulación de procesos hidrológicos utilizando técnicas de
machine learning y modelos hidrológicos

Autor:

Patricia Jimeno Sáez

Directores:

Dr. D. Javier Senent Aparicio
Dr. D. David Pulido Velázquez

Murcia, junio de 2018



UCAM
UNIVERSIDAD CATÓLICA
DE MURCIA

AUTORIZACIÓN DE LOS DIRECTORES DE LA TESIS
PARA SU PRESENTACIÓN

El Dr. D. Javier Senent Aparicio y el Dr. D. David Pulido Velázquez como Directores de la Tesis Doctoral titulada “Simulación de procesos hidrológicos utilizando técnicas de machine learning y modelos hidrológicos” realizada por Dña. Patricia Jimeno Sáez en el Departamento de Ciencias Politécnicas, **autoriza su presentación a trámite** dado que reúne las condiciones necesarias para su defensa.

Lo que firmo, para dar cumplimiento al Real Decreto 99/2011, 1393/2007, 56/2005 y 778/98, en Murcia a 11 de junio de 2018

COMPENDIO DE PUBLICACIONES

Esta memoria se presenta en la modalidad de compendio de publicaciones. Los artículos publicados y aceptados que constituyen la tesis son los siguientes:

- **Publicación 1:** Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., y Pulido-Velazquez, D. (2018). A Comparison of SWAT and ANN Models for Daily Runoff Simulation in Different Climatic Zones of Peninsular Spain. *Water*, 10(2), 192. <https://doi.org/10.3390/w10020192>
- **Publicación 2:** Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., Pulido-Velazquez, D., y Cecilia, J. M. (2017). Estimation of Instantaneous Peak Flow Using Machine-Learning Models and Empirical Formula in Peninsular Spain. *Water*, 9(5), 347. <https://doi.org/10.3390/w9050347>
- **Publicación 3:** Senent-Aparicio, J., Jimeno-Sáez, P., Bueno-Crespo, A., Pérez-Sánchez, J., y Pulido-Velazquez, D. (2018). Coupling machine-learning techniques with SWAT model for instantaneous peak flow prediction. *Biosystems Engineering*, (in press) <https://doi.org/10.1016/j.biosystemseng.2018.04.022>

Además, esta tesis cuenta con un cuarto artículo que se encuentra bajo revisión:

- **Publicación 4:** Jimeno-Sáez, P., Pulido-Velazquez, D., Cuellar, M.P., Pardo-Igúzquiza, E., Collados-Lara, A.J., Senent-Aparicio, J. Combined use of geostatistic and hydrological models for a preliminary assessment of “under-catch” and precipitation pattern in alpine basins (Canales Basin, Sierra Nevada, Spain), (under review).

AGRADECIMIENTOS

Mi mayor agradecimiento al Dr. Javier Senent Aparicio y al Dr. David Pulido Velázquez, directores de esta tesis doctoral, ya que sin su orientación y apoyo esta tesis no hubiera sido posible.

Deseo expresar mis más sinceros agradecimientos a todas aquellas personas que me brindaron su ayuda y colaboración, sus conocimientos, su dedicación y tiempo durante la realización de esta tesis.

También, agradezco a la Universidad Católica de Murcia el haber financiado gran parte de mis estudios doctorales con un contrato predoctoral.

Le doy gracias a Dios por haberme guiado y por ser mi fortaleza a lo largo de estos largos años. A toda mi familia por apoyarme en todo momento. A mi marido por ser parte importante de mi vida, por su paciencia y amor incondicional. Y a mi pequeña hija por ser mi gran motivación y alegría. A ella, que aún en mi vientre, me ha estado acompañando los últimos meses de este gran recorrido.

"Los progresos científicos más extraordinarios, las proezas técnicas más sorprendentes, el crecimiento económico más prodigioso, si no van acompañados por un auténtico progreso social y moral, se vuelven en definitiva contra el hombre".

Pablo VI (1897-1978).

ÍNDICE GENERAL

AUTORIZACIÓN DE LOS DIRECTORES	
COMPENDIO DE PUBLICACIONES	
AGRADECIMIENTOS	
ÍNDICE GENERAL.....	13
SIGLAS Y ABREVIATURAS	17
ÍNDICE DE FIGURAS	21
ÍNDICE DE TABLAS	22
RESUMEN.....	25
ABSTRACT	29
I - INTRODUCCIÓN.....	33
1.1 INTRODUCCIÓN	35
1.1.1 Simulación de caudales	35
1.1.2 Estimación de caudales máximos instantáneos	39
1.2 JUSTIFICACIÓN DE LA INVESTIGACIÓN.....	40
1.3 OBJETIVOS	44
1.4 ESTRUCTURA DE LA TESIS	47
II – ANTECEDENTES Y ESTADO DEL ARTE	49
2.1 MODELACIÓN LLUVIA-ESCORRENTÍA: MODELADO DE SERIES TEMPORALES DE CAUDALES EN CUENCAS.....	51
2.2 ESTIMACIÓN DE CAUDALES MÁXIMOS INSTANTÁNEOS	57
III –METODOLOGÍA DE LA INVESTIGACIÓN	61
3.1 DESCRIPCIÓN DE LAS ZONAS DE ESTUDIO.....	63
3.2 MODELO SWAT	68
3.2.1 Componentes del modelo SWAT.....	71
3.2.2 Análisis de sensibilidad, calibración y validación del modelo SWAT	74

3.3 MODELO STM Y CORRECCIÓN DEL <i>UNDER-CATCH</i>	76
3.3.1 Modelo de Témez.....	76
3.3.2 Modelo de Nieve	80
3.4 ALGORITMOS DE MACHINE LEARNING	83
3.4.1 Red neuronal artificial (RNA)	84
3.4.2 Sistemas adaptativos de inferencia neuro-difusa (ANFIS)	92
3.4.3 Máquinas de Vectores de Soporte (SVM)	95
3.4.4 Extreme Learning Machine (ELM)	96
3.5 FÓRMULAS EMPÍRICAS PARA CAUDALES MÁXIMOS INSTANTÁNEOS	98
3.5.1 Fuller	98
3.5.2 Fórmulas del CEDEX (Regionalizaciones de la fórmula de Fuller)	99
3.5.3 Sangal.....	100
3.5.4 Fill-Steiner	100
IV – PUBLICACIONES.....	103
4.1 PUBLICACIÓN 1: A COMPARISON OF SWAT AND ANN MODELS FOR DAILY RUNOFF SIMULATION IN DIFFERENT CLIMATIC ZONES OF PENINSULAR SPAIN	108
4.2 PUBLICACIÓN 2: ESTIMATION OF INSTANTANEOUS PEAK FLOW USING MACHINE-LEARNING MODELS AND EMPIRICAL FORMULA IN PENINSULAR SPAIN	128
4.3 PUBLICACIÓN 3: COUPLING MACHINE-LEARNING TECHNIQUES WITH SWAT MODEL FOR INSTANTANEOUS PEAK FLOW PREDICTION	141
4.4 PUBLICACIÓN 4: COMBINED USE OF GEOSTATISTIC AND HYDROLOGICAL MODELS FOR A PRELIMINARY ASSESSMENT OF “UNDER-CATCH” AND PRECIPITATION PATTERN IN ALPINE BASINS (CANALES BASIN, SIERRA NEVADA, SPAIN).....	153
4.5 SÍNTESIS DE RESULTADOS Y DISCUSIÓN	185

4.5.1 Simulación hidrológica con los modelos SWAT y RNA	185
4.5.2 Estimación del caudal máximo instantáneo utilizando técnicas de machine learning frente a fórmulas empíricas.....	200
4.5.3 Combinación de las técnicas de machine learning con SWAT para la predicción de caudales máximos instantáneos	206
4.5.4 Uso combinado de modelos geoestadísticos e hidrológicos para evaluar errores sistemáticos en la medición de la precipitación en cuencas alpinas.....	213
V – CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN.....	221
VI - REFERENCIAS BIBLIOGRÁFICAS.....	227
APENDICE: CALIDAD DE LAS PUBLICACIONES.....	247

SIGLAS Y ABREVIATURAS

ALPHA_BF	Coeficiente de agotamiento del flujo base
AND	Estación de aforo de Andoain
ANN	Artificial neural network
ANFIS	Sistemas adaptativos de inferencia neuro-difusa (Adaptative Network based in Fuzzy Inference Systems)
BEG	Estación de aforos de Begonte
BEL	Estación de aforo de Belmontejo
BIOMIX	Eficiencia de la mezcla biológica
BOL	Estación de aforo de Bolulla
Bsk	Clasificación climática de Koppen: Clima semiárido
CANMX	Capacidad máxima de interceptación vegetal
CDC	Curvas de duración del caudal
CEDEX	Centro de Estudios y Experimentación de Obras Públicas
CE	Comisión Europea
Cfb	Clasificación climática de Koppen: clima oceánico
CH_K1	Conductividad hidráulica efectiva en canales tributarios
CH_K2	Conductividad hidráulica efectiva en canal principal
CH_N1	Número de Manning en los canales tributarios
CH_N2	Número de Manning para el canal principal
CN2	SCS número de curva
CNCOEF	Coeficiente para el cálculo del número de curva dependiente de la evapotranspiración de la planta
COT	Estación de aforo de Coterillo
Csa	Clasificación climática de Koppen: clima típico mediterráneo con veranos secos y calurosos
Csb	Clasificación climática de Koppen: clima mediterráneo con veranos más suaves y con influencia oceánica
CUE	Estación de aforo de Cuernacabras
DEM	Modelo digital de elevación
DGA	Dirección General del Agua
ELM	Máquina de aprendizaje extremo (Extreme Learning Machine)
EPCO	Factor de compensación de la captación de las plantas
ESCO	Factor de compensación de la evaporación del suelo
FIS	Sistema de inferencia difuso
GAR	Estación de aforo de Gargüera
GW_DELAY	Tiempo de retardo del agua subterránea (días)
GW_REVAP	Coeficiente "revaporación" del flujo subterráneo

GWQMN	Profundidad umbral de agua en el acuífero superficial para que se produzca flujo de retorno
HRU	Unidad de respuesta hidrológica
HSRB	Cuenca cabecera del río Segura
IA	Inteligencia Artificial
IGME	Instituto Geológico y Minero de España
IPF	Instantaneous Peak Flow
JUB	Estación de aforos de Jubera
KED	Kriging con deriva externa
LAT_TTIME	Tiempo de viaje del flujo lateral
LIC	Lugar de Importancia Comunitaria
LM	Algoritmo de <i>backpropagation</i> de Levenberg-Marquardt
LRB	Cuenca del río Ladra
MAPAMA	Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente
MF	Función de pertenencia
ML	Machine Learning
MLP	Red perceptrón multicapa (Multilayer Perceptron)
MMDF	Maximum mean daily flow
MQ_{md}	Máximo caudal medio diario
MSE	Error cuadrático medio
NSE	Coefficiente de eficiencia de Nash-Sutcliffe
OV_N	Número de Manning para el flujo terrestre
PBIAS	Porcentaje de error
PER	Estación de aforo de Peralejo de las Truchas
PIT	Estación de aforo de Pitarque
PRI	Estación de aforo de Priego
Q_{ins}	Caudal máximo instantáneo
Q_{md}	Caudal medio diario
R²	Coefficiente de determinación
RCHRG_DP	Factor de percolación al acuífero profundo
REVAPMN	Umbral de profundidad del agua en el acuífero superficial para "revaporación" a la capa de suelo o percolación al acuífero profundo
RIA	Estación de aforo de Riaza
RK	Regression-kriging
RMSE	Raíz del error cuadrático medio
RNA	Red Neuronal Artificial
ROEA	Red Oficial de Estaciones de Aforo

SCS	Servicio de Conservación de Suelos de Estados Unidos
SLFN	Red neuronal feed-forward con una sola capa (Single-Layer Feedforward Network)
SLSUBBSN	Longitud promedio de la pendiente
SNCZI	Sistema Nacional de Cartografía de Zonas Inundables
SOL_AWC	Capacidad de agua disponible de la capa del suelo
SOL_K	Conductividad hidráulica saturada
STM	Snow-Témez Model
SURLAG	Coefficiente de retraso de la escorrentía superficial
SVM	Máquinas de vector soporte (Support Vector Machines)
SVR	Support Vector Regression machines
SWAT	Soil and Water Assessment Tool
SWAT-CUP	SWAT – Calibration Uncertainly Procedures
TIM	Temperature Index Model
TRA	Estación de aforo de Tramacastilla
TRE	Estación de aforo de Trevías
UE	Unión Europea

ÍNDICE DE FIGURAS Y DE TABLAS

ÍNDICE DE FIGURAS

Figura 1. (a) Localización de las cuencas Miño-Sil y Segura en la España peninsular; (b) Ubicación de la cuenca LRB en la cuenca del río Miño-Sil; (c) Ubicación de la cuenca HSRB en la cuenca del río Segura; (d) DEM de LRB; (e) DEM de HSRB.	63
Figura 2. Localización de la cuenca de Canales dentro de la cuenca del río Genil.	66
Figura 3. Localización de las 14 cuencas para el estudio de estimación de caudales instantáneos.	67
Figura 4. Esquema de la fase terrestre del ciclo hidrológico en SWAT. Fuente: Adaptación propia de SWAT User's Manual (2000).	70
Figura 5. Esquema del ciclo hidrológico del modelo de Témez.	77
Figura 6. Diagrama del modelo STM (Snow-Témez Model).	83
Figura 7. Arquitectura de la red perceptrón multicapa, donde: n es el número de variables de entrada a la red; L es el número total de capas ocultas; y k es el número de variables de salida de la red.	85
Figura 8. Modelo matemático de una neurona j en una RNA. Fuente: Ochoa-Rivera, García-Bartual, & Andreu (2002).	87
Figura 9. Funciones de activación tipo escalón o umbral.	89
Figura 10. Funciones de activación tipo mixta o semi-lineal.	89
Figura 11. Función sigmoide logística (izquierda) y función sigmoide tangente hiperbólica (derecha).	90
Figura 12. (a) Modelo difuso de Sugeno de primer orden; (b) Arquitectura ANFIS.	94
Figura 13. Análisis de correlación cruzada para LRB y HSRB entre el caudal diario y (a) la precipitación diaria; (b) la precipitación total de los n días precedentes; (c) temperatura diaria; (d) temperatura media de los n días precedentes.	190
Figura 14. Estructura de la red MLP utilizada en esta investigación.	192
Figura 15. Diagrama de dispersión del caudal diario simulado frente al observado, en rojo los resultados de SWAT y en negro los resultados de la RNA (ANN, por sus siglas en inglés) (a) para el periodo de calibración de la cuenca LRB; (b) para el periodo de validación de la cuenca LRB; (c) para el periodo de calibración de la cuenca HSRB; (d) y para el periodo de validación de la cuenca HSRB.	195

Figura 16. Caudal diario simulado por SWAT (en rojo) y RNA (en negro) frente al caudal observado (en verde) en la fase de validación; el gráfico de barras en la parte superior es la precipitación diaria; (a) para la cuenca LRB; (b) para la cuenca HSRB.	196
Figura 17. CDC del periodo de validación de la cuenca (a) LRB; (b) y HSRB.	197
Figura 18. Arquitectura de la RNA de tipo MLP utilizada en la estimación de los Q_{ins} (IPF, por sus siglas en inglés) a partir del MQ_{md} (MMDF, por sus siglas en inglés).	202
Figura 19. Diagramas de dispersión del Q_{ins} observado y el estimado obtenido con el modelo de RNA versus ANFIS para la fase de test. Las letras en la parte superior izquierda de cada subfigura muestran los códigos de la cuenca (ver Tabla 2).	205
Figura 20. Comparación de los caudales diarios observados y simulados con SWAT en el periodo de validación del río Ladra; (a) curvas de duración de caudales; (b) hidrograma diario.	209
Figura 21. . Diagrama de la aplicación de acoplamiento de SWAT y la técnica de machine learning (ELM) para predecir Q_{ins} (IPF, por sus siglas en inglés).	211
Figura 22. Comparación entre el valor estimado y observado de Q_{ins} (IPF, por sus siglas en inglés) para el periodo (1973-2014) en la cuenca del río Ladra.	212
Figura 23. Precipitación mensual media corregida frente a la estimada y su distribución anual entre fase líquida y sólida; (a) experimento Linear KED; (b) experimento RK.	215
Figura 24. Caudal mensual medio (año medio); (a) utilizando precipitación del experimento RK; (b) utilizando precipitación del experimento Linear KED.	216
Figura 25. Caudal mensual simulado frente al observado; (a) con datos de precipitación RK; (b) con datos de precipitación KED-Lineal.	218
Figura 26. Precipitación diaria media corregida según la elevación de la cuenca frente a la precipitación sin corregir.	219

ÍNDICE DE TABLAS

Tabla 1. Características de las cuencas LRB y HSRB.	64
Tabla 2. Resumen de las principales características de las 14 cuencas seleccionadas para el estudio de estimación de caudales instantáneos.	68
Tabla 3. Fórmula de Fuller regionalizadas por CEDEX (2011) para doce cuencas de España.	100
Tabla 4. Análisis de sensibilidad de los parámetros del modelo SWAT para las cuencas LRB y HSRB.	186

Tabla 5. Parámetros usados en la calibración del modelo SWAT en las cuencas LRB y HSRB.	188
Tabla 6. Escenarios de predicción con las diferentes combinaciones de inputs consideradas para las RNAs en cada cuenca.	191
Tabla 7. Mejor arquitectura de red neuronal y sus rendimientos medios obtenidos en la validación cruzada para cada escenario de predicción.	192
Tabla 8. Criterios de evaluación del modelo para escala diaria.	193
Tabla 9. Rendimientos para los modelos SWAT y RNA.	194
Tabla 10. Valores del RMSE (m^3/s) de los modelos SWAT y RNA para cada fase del hidrograma.	198
Tabla 11. Evaluación de los resultados obtenidos con las fórmulas empíricas basada en el valor de R^2 y RMSE.	201
Tabla 12. Estadísticos del ajuste obtenido con los modelos de RNAs, ANFIS y la mejor fórmula empírica en la estimación de Q_{ins}	203
Tabla 13. Parámetros calibrados en el modelo SWAT para la cuenca del río Ladra con el objetivo de obtener los MQ_{md}	207
Tabla 14. Valores iniciales de MNSE y d , y valores para la fase de calibración y validación de los caudales diarios.	209
Tabla 15. Estadísticos obtenidos en la fase de entrenamiento y de test (media \pm desviación estándar de la validación cruzada) en la estimación del Q_{ins}	210
Tabla 16. Bondad de ajuste a escala mensual del modelo STM para los datos de calibración y validación y valores de C_r y C_s para cada experimento.	214

RESUMEN

Son muchas las razones por las que se necesita modelar el proceso lluvia-escorrentía, en concreto la modelación de los caudales. La razón principal son las limitaciones existentes en las técnicas de medición hidrológica, disponiéndose solamente de un rango limitado de mediciones o registros en el espacio y en el tiempo. Por ello, resulta importante disponer de medios que ayuden a extrapolar esas mediciones en el espacio y en el tiempo, particularmente en cuencas no aforadas, donde los datos no están disponibles, y en el futuro, donde las mediciones no son posibles, para evaluar el posible impacto del cambio hidrológico futuro. La estimación y evaluación de los caudales es esencial para la gestión sostenible de los recursos hídricos. Y encontrar modelos que realicen estimaciones de caudales lo más precisas posibles es fundamental a la hora de tomar decisiones. Sin embargo, la estimación precisa de los caudales a escala de cuenca es compleja debido a la gran variabilidad espacial y temporal de las características de la cuenca y de los patrones climáticos, así como de una incompleta comprensión de los complejos procesos físicos subyacentes. La complejidad hidrológica de una cuenca queda claramente reflejada en las diferentes fases de la serie temporal de caudales. Siempre ha sido un gran reto para los modelos hidrológicos la representación adecuada de todas las fases del hidrograma de caudales con el mismo conjunto de parámetros del modelo. Otra problemática a tener en cuenta en la modelación de los caudales en zonas de alta montaña, es la correcta modelación de los procesos nivales y la estimación de los errores sistemáticos en la medición de la precipitación sólida. La modelación del fenómeno de acumulación-fusión de la nieve es esencial para desarrollar una explotación óptima de los embalses de cabecera, así como realizar la previsión de posibles avenidas motivadas por una rápida fusión de la nieve.

Los modelos físicamente basados tienen la ventaja de considerar los procesos físicos de control, pero al mismo tiempo sus requisitos de datos también son altos. A menudo, incluso en cuencas hidrográficas intensamente monitorizadas, todos los datos requeridos no están disponibles. Por lo tanto, existe la necesidad de buscar métodos alternativos para la predicción de variables hidrológicas utilizando información fácilmente disponible. Los datos de precipitación y temperatura suelen ser más abundantes que los de caudal y su

recopilación es más sencilla y tiene un menor coste. En la presente tesis se propuso el uso de SWAT, un modelo físicamente basado, y de las RNAs (Redes neuronales artificiales), una técnica de aprendizaje automático, para simular los valores de caudales diarios. La RNA utilizada solo considera las entradas de precipitación y temperatura para la obtención de los caudales diarios. Debido a que el flujo de agua en una cuenca está intrínsecamente sujeto a episodios extremos de flujos altos y bajos, la eficiencia de los modelos además fue analizada en los diferentes rangos del caudal, desde caudales muy altos a caudales muy bajos, utilizando las curvas de duración de caudales para este propósito. Los resultados indicaron que SWAT tuvo un mejor rendimiento en la estimación de valores de caudal muy bajos, mientras que las RNAs estimaron los valores muy altos de caudal con mayor precisión en los casos estudiados. Además, estos modelos fueron mejores cuando el clima era más húmedo. Por otro lado, con el propósito de mejorar la simulación de caudales en cuencas de alta montaña, donde la componente nival juega un papel importante, se desarrolló un modelo formado por un modelo distribuido de nieve acoplado al modelo agregado de Témez. En este modelo nival se utilizaron datos climáticos obtenidos con diferentes enfoques geostatísticos para modelar los caudales. Los datos de precipitación fueron corregidos por dos factores correctores, y los resultados mostraron claramente la existencia del fenómeno de *under-catch* en la precipitación, y la necesidad de corregir los datos de precipitación para mejorar los resultados de las simulaciones. Corregir la precipitación fue la única manera de poder aproximar el caudal simulado al caudal histórico promedio anual y captar el pico del hidrograma debido al proceso de fusión de la nieve.

Además de la importancia de conocer los caudales medios diarios, un dato fundamental para el dimensionamiento de infraestructuras en una cuenca hidrográfica es el valor máximo del caudal instantáneo (Q_{ins}). Por ello la importancia de estudiar y analizar diferentes técnicas que reduzcan las incertidumbres asociadas a la estimación de los Q_{ins} . En la presente tesis, se analiza el rendimiento de diferentes fórmulas empíricas y se comparan los resultados obtenidos en la estimación de los Q_{ins} a partir de los caudales medios diarios con los obtenidos con diferentes técnicas de machine learning, como son las RNAs y los sistemas adaptativos de inferencia neuro-difusa (ANFIS). Los métodos de aprendizaje automático fueron superiores a las fórmulas empíricas

con los datos utilizados y en las cuencas caso de estudio. También se analizaron otras técnicas de machine learning como las máquinas de vector soporte (SVM) y las redes extreme learning machines (ELM). Y se exploró la posibilidad de acoplar un modelo SWAT con estas técnicas de aprendizaje automático para obtener la magnitud del Q_{ins} . Como resultado de esta evaluación, todas las técnicas de aprendizaje automático investigadas en este estudio se pueden usar en la predicción de Q_{ins} , aunque la técnica ELM se comportó ligeramente mejor que los otros métodos. Concluyendo que los resultados de este estudio pueden contribuir en las tareas de predicción de los Q_{ins} en áreas donde los datos a escalas de tiempo sub-diarias son escasos o no están disponibles, pudiendo así reducir las incertidumbres asociadas a estas estimaciones.

Palabras clave: Modelo SWAT, aprendizaje automático, red neuronal artificial, simulación del caudal, modelo hidrológico, máximo caudal instantáneo, precipitación sólida, *under-catch*.

ABSTRACT

There are many reasons why it is necessary to model the rain-runoff process, especially the modeling of the streamflows. The main reason is the limitations in hydrological measurement techniques, with a limited range of measurements in space and time. Therefore, it is important to have techniques that help extrapolate these measurements in space and time, particularly in ungauged basins, where data is not available, and in the future, where measurements are not possible, to evaluate the possible impact of future hydrological change. The estimation of the streamflows is essential for the management of the basins, as well as for the sustainable development of the water resources. Finding models that make streamflow estimates as accurate as possible is essential when making decisions. However, the precise estimation of the streamflows at the basin scale is complex due to the great spatial and temporal variability of the characteristics of the basin and the weather patterns, as well as an incomplete understanding of the complex underlying physical processes. The hydrological complexity of a basin is clearly reflected in the different phases of the time series of streamflows. It has always been a great challenge for hydrological models to adequately represent all phases of streamflow with the same set of model parameters. Another problem to be taken into account in the modeling of streamflows in high mountain areas is the correct modeling of the snow processes and the estimation of the systematic errors in the measurement of solid precipitation. The modeling of the snow accumulation-melting phenomenon is essential to develop an optimal exploitation of the headwater reservoirs, as well as to forecast possible avenues caused by a rapid melting of the snow.

Physically based models have the advantage of considering the physical processes of control, but at the same time their data requirements are also high. Often, even in intensively monitored watersheds, all required data is not available. Therefore, it is necessary to look for alternative methods for the prediction of hydrological variables using easily available information. The data of precipitation and temperature are usually more abundant than the streamflow data and its collection is easier and has a lower cost. In the present thesis the use of SWAT, a physically based model, and the ANNs (Artificial Neural Networks), a machine learning technique, were proposed to simulate the daily streamflows.

The ANN used only considers the inputs of precipitation and temperature to obtain the daily streamflow. Because the streamflow in a basin is intrinsically subject to extreme episodes of high and low flows, the efficiency of the models was also analyzed in the different flow ranges, from very high flows to very low flows, using the flow duration curves for this purpose. The results indicated that SWAT had a better performance in estimating very low values of streamflow, whereas ANN estimated very high values with greater precision in all cases studied. In addition, these models had a better performance when the climate was more humid. On the other hand, with the purpose of improving the simulation of streamflows in high mountain basins, where the snow component plays an important role, a model was developed consisting of a distributed snow model coupled with the aggregate model of Témez. In this snow model, climatic data obtained with different geostatistical approaches were used to model the streamflows. The precipitation data were corrected by two correction factors, and the results clearly showed the existence of the phenomenon of under-catch in the precipitation, and the need to correct the precipitation data to improve the results of the simulations. Correcting precipitation was the only way to be able to approximate the simulated flow to the annual average historical flow and capture the peak of the hydrograph due to the melting process of the snow.

In addition to the importance of knowing the daily average streamflow, an important streamflow data to know in a watershed is the instantaneous peak flow (IPF). However, these data are not always available, so in these cases their estimation is necessary. The estimation of the frequency and magnitude of the IPF is fundamental for the management of flood risk and also for the design of hydraulic structures. Therefore, the importance of studying and analyzing different techniques that reduce the uncertainties associated with the estimation of the IPF. In the present thesis, the performance of different empirical formulas is analyzed and the results obtained in the estimation of the IPF are compared from the daily average flows with those obtained using different machine learning techniques, such as RNAs, adaptive systems of neuro-diffuse inference (ANFIS). The machine learning methods were superior to the empirical formulas with the data used and in the case study basins. We also analyzed machine learning techniques such as support vector machines (SVM) and extreme learning machines (ELM) networks. We explored the possibility of coupling a SWAT

model with these automatic learning techniques to obtain the magnitude of the IPF. As a result of this evaluation, all the machine learning techniques investigated in this study can be used in the prediction of IPF, although the ELM technique performed slightly better than the other methods. Concluding that the results of this study may contribute to IPF prediction tasks in areas where data at sub-daily time scales are scarce or not available, thus reducing the uncertainties associated with these estimates.

Keywords: SWAT model, machine learning, artificial neural network, streamflow simulation, hydrologic model, instantaneous peak flow, snow model, *under-catch*.

I - INTRODUCCIÓN

I - INTRODUCCIÓN

1.1 INTRODUCCIÓN

1.1.1 Simulación de caudales

El agua dulce es un recurso escaso y fundamental, que forma parte de todos los procesos sociales y medioambientales. Ya en los primeros asentamientos humanos, una de las mayores preocupaciones eran los problemas relacionados con el agua, tanto la preocupación por la protección frente a las inundaciones como por la garantía de un adecuado y constante abastecimiento de agua potable (Simonovic, 2000). Desde finales del siglo pasado se han producido grandes cambios en la gestión hídrica, llevando a la sociedad a ser cada vez más consciente de que el agua es un elemento fundamental en el medio ambiente y que es absolutamente esencial para el ser humano y para todos los sectores económicos, tanto para la agricultura y la producción de alimentos, como para la producción industrial y la generación de energía.

Una de las principales fuentes de agua dulce son los ríos. Los ríos proporcionan numerosos bienes y servicios a la humanidad, son una fuente de agua tanto para uso doméstico, industrial y agrícola, pueden ser un medio para la generación de energía o para el vertido de aguas residuales, y también pueden servir como rutas de navegación y como espacios para actividades recreativas. El caudal es volumen de agua que circula por unidad de tiempo en una sección transversal de un río y es una de las variables hidrológicas más significativas y uno de los componentes principales del ciclo hidrológico. El caudal es el resultado de la acumulación de la escorrentía superficial con la aportación subterránea. Los caudales, además de ser importantes fuentes de agua dulce disponible para los seres humanos, regulan los ciclos ecológicos de los ríos. También son el enlace entre las aguas continentales y las oceánicas, proporcionando enormes cantidades de partículas y materiales disueltos a los océanos, lo que supone un gran impacto en la composición química y en el contenido de nutrientes de los océanos. En el contexto de la mejora del estado ecológico y de la biodiversidad de las cuencas

fluviales, los datos de caudal son fundamentales para determinar los caudales ecológicos (Sun, Ishidaira, Bastola, & Yu, 2015). La evolución del cambio climático augura un aumento de las frecuencias de los fenómenos climáticos extremos, como las sequías y las inundaciones (Hirabayashi, Kanae, Emori, Oki, & Kimoto, 2008), y las series de datos de caudales a largo plazo son también importantes para la toma de decisiones contra estos desastres. Por tanto, los datos de caudales son necesarios para la planificación y gestión de los recursos hídricos.

Los datos de caudales se miden tradicionalmente mediante medición *in situ*. En España hay disponible una “Red Oficial de Estaciones de Aforo” (ROEA) que proporciona datos de nivel y de caudal en puntos seleccionados de los ríos, además de otros datos de embalses, conducciones y estaciones evaporimétricas asociadas a los embalses. Los Organismos de Cuenca son los responsables de la operación y mantenimiento de estos aforos y el Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente (MAPAMA) tiene a su cargo el archivo y la difusión de los datos a través de la Dirección General del Agua (DGA). La red ROEA permite conocer la evolución de caudales en puntos singulares de cauces y canales, pudiendo así el MAPAMA mantener una estadística que permite la vigilancia de la cantidad de aguas continentales. El Centro de Estudios y Experimentación de Obras Públicas (CEDEX) colabora con la DGA en las tareas de recopilación de la información foronómica, tratamiento de los datos, incorporación y almacenamiento de la información en una base de datos y su posterior publicación en forma de anuarios. Entre la información básica que se incluyen en los anuarios de aforos se encuentran los datos medios diarios de caudal de las estaciones de aforo en ríos, completada con los máximos instantáneos en el mes; los datos diarios de volumen embalsado y el caudal medio diario de salida del embalse.

En muchas ocasiones los datos históricos de caudales medidos directamente en los ríos pueden no ser suficientes, es decir, pueden ser series cortas y/o incompletas. Además, puede que sean de dudosa fiabilidad como para poder trabajar directamente con ellas, debido a que estos datos de caudales se miden en aforos colocados en cauces y embalses, siendo muy fácil que haya errores de medición ocasionales (Sahuquillo, Cassiraga, Solera, & Murillo, 2011). Por esta razón, es conveniente mejorar esta información recurriendo a la utilización de datos históricos climáticos, como datos de precipitación y temperatura, y

características físicas de la cuenca para realizar una tarea de simulación de caudales. La estimación de caudales ha sido desde hace décadas un tema de gran interés para los hidrólogos e ingenieros civiles por la importancia ya comentada de disponer de estos datos.

Los modelos hidrológicos son importantes herramientas para simular las series de caudales, siendo estos capaces de establecer las relaciones del proceso lluvia-escorrentía. Los modelos hidrológicos se utilizan para evaluar una amplia gama de problemas hidrológicos, como el cambio climático, los cambios en los usos del suelo, para predecir eventos extremos como inundaciones o sequías, o para la planificación y gestión de los recursos hídricos (Pfannerstill, Guse y Fohrer, 2014). La modelación de caudales es una tarea compleja puesto que el caudal es estocástico por naturaleza, el flujo de agua varía con el tiempo como respuesta a la precipitación y está intrínsecamente sujeto a episodios extremos de flujos altos y bajos. Además el caudal varía entre las cuencas hidrográficas debido a las diferentes características fisiográficas y paisajísticas (Srivastava, McNair, & Johnson, 2006).

Son numerosos los modelos hidrológicos que se han desarrollado durante las últimas cuatro décadas gracias a los rápidos avances producidos en la ciencia de la computación y a la gran disponibilidad de bases de datos digitales. Los modelos hidrológicos pueden ser clasificados en determinísticos y estocásticos. En los modelos determinísticos, el sistema es descrito y representado mediante relaciones físicas teóricas y/o empíricas, existiendo una relación unívoca entre el input y el output, y en ellos no se contempla la existencia del azar ni de incertidumbre, ni se evalúa la probabilidad de ocurrencia. Los modelos deterministas permiten un solo resultado en una simulación con un conjunto de datos de entrada y unos valores de los parámetros. Por otra parte, en los modelos estocásticos se renuncia a obtener algún tipo de relación o exactitud entre las entradas y salidas para centrarse en la captación de las características estadísticas relevantes de las series históricas. Los modelos estocásticos permiten cierta aleatoriedad o incertidumbre en los posibles resultados debido a la incertidumbre en las variables de entrada, las condiciones de contorno o los parámetros del modelo.

Los modelos determinísticos, que son los empleados en la presente tesis, a su vez pueden ser clasificados en tres tipos de modelos: empíricos, conceptuales y físicamente basados. En un extremo se encuentran los modelos empíricos basados en técnicas de caja negra, los cuales transforman las entradas, como es la precipitación, en un hidrograma del caudal saliente de la cuenca sin considerar ninguno de los procesos físicos involucrados. Estos modelos son sencillos, basados en conceptos muy generales con respecto a los procesos que intervienen en la transformación de los datos de entrada en los datos de salida, y generalmente requieren menos datos. Un modelo particular de caja negra son las redes neuronales artificiales (RNAs), cada vez más empleadas para la resolución de problemas hidrológicos. En el otro extremo de los modelos determinísticos se encuentran los modelos físicamente basados, los cuales están basados en sistemas de ecuaciones complejas y en leyes físicas que determinan los procesos hidrológicos de una cuenca hidrográfica. Un ejemplo de un modelo determinístico físicamente basado es el modelo SWAT. Entre ambos extremos, existen múltiples modelos de tipo conceptual basados en conceptos simplificados a través de formulaciones matemáticas que tienen en consideración los diferentes procesos del ciclo hidrológico que intervienen en la formación del caudal de salida. Un ejemplo es el modelo lluvia-escorrentía de Témez. La aplicación de estos modelos determinísticos conceptuales es muy sencilla, siendo la mayor dificultad la calibración de los mismos. Los parámetros suelen ser determinados mediante métodos o algoritmos iterativos basados en datos históricos de entrada y salida. Debido a las limitaciones de los datos, a las imperfecciones del modelo y a las interrelaciones entre los parámetros, a mayor número de parámetros, mayores serán las dificultades en la calibración debido a la obtención de óptimos locales. Por ello, es deseable que los modelos sean lo más simples posible para obtener resultados más precisos (Organización Meteorológica Mundial [OMM], 2011).

Los modelos a escala de cuenca pueden clasificarse además en función de su representación espacial como modelos agregados, semi-distribuidos o distribuidos. En los modelos agregados se considera a la cuenca como una sola unidad para los cálculos, y en ellos los parámetros y las variables de la cuenca se promedian. En los modelos semi-distribuidos y distribuidos si se tiene en cuenta

la variabilidad espacial de los procesos que intervienen en el modelo, variables de entrada, condiciones de contorno y características de la cuenca.

1.1.2 Estimación de caudales máximos instantáneos

Además de los caudales medios diarios, en una cuenca resulta fundamental conocer el caudal máximo instantáneo (Q_{ins}). El Q_{ins} es el valor máximo de caudal ocurrido en una sección de control y alcanzado durante una avenida en un periodo determinado. Los datos de Q_{ins} son importantes para resolver una serie de problemas medioambientales y de ingeniería.

El creciente número de desastres naturales ha demostrado a la Comisión Europea (CE) y a los Estados miembros de la Unión Europea (UE) la gran importancia de la cuestión de los riesgos naturales para la protección del medio ambiente y de la población (Barredo, 2007). Las inundaciones repentinas son uno de los peligros naturales más importantes en Europa, y especialmente en los países mediterráneos (Gaume et al., 2009). En el periodo 1950-2005, España fue el país de Europa más afectado por las inundaciones repentinas, las cuales causaron grandes pérdidas económicas y humanas (Barredo, 2007). Las inundaciones son la catástrofe natural que más daños genera en España. Según datos del Consorcio de Compensación de Seguros y el Instituto Geológico y Minero de España (IGME), en nuestro país, los daños por inundaciones se estiman en total en una media de 800 millones de euros anuales (Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente [MAPAMA], 2018).

La llegada de avenidas a un determinado punto de un río es un fenómeno natural muy variable en frecuencia y en magnitud, y determinado por el azar. Por ello, la mayoría de los estudios hidrológicos de crecidas consisten en caracterizar estadísticamente dicho fenómeno natural mediante el conocimiento de su ley de frecuencia, la cual relaciona la magnitud del caudal punta de avenida con su frecuencia de presentación, expresada mediante el periodo de retorno (Centro de Estudios y Experimentación de Obras Públicas [CEDEX], 2011).

En el caso del dimensionamiento hidráulico de una obra, elemento o sistema de drenaje superficial de una carretera, el caudal de proyecto a tener en cuenta es el caudal máximo anual correspondiente a un determinado periodo de retorno (Orden FOM/298/2016, de 15 de febrero). El diseño de estructuras

hidráulicas para controlar inundaciones también se basa en los caudales máximos instantáneos puesto que estos pueden ser considerablemente diferentes a los valores de caudales medios. Sin embargo, la variable hidrológica más comúnmente registrada por las agencias gubernamentales son los datos relacionados con los caudales medios diarios. En muchos casos, la utilización de los datos de caudal medio diario (Q_{md}) para el diseño de estructuras de control de avenidas puede hacer que éstas se subestimen, con el consiguiente riesgo de un posible colapso de las mismas (Taguas et al., 2008). Tal y como sucede en otros países, los organismos españoles de gestión de cuencas registran los datos relacionados con el Q_{md} , pero no siempre los de los máximos instantáneos, por lo que la disponibilidad de series temporales de Q_{ins} es menos frecuente.

La única forma de conocer los Q_{ins} con precisión es midiéndolos. Una vez que este caudal no ha sido medido cualquier intento de conocerlo con posterioridad dará un valor aproximado (CEDEX, 2011), por este motivo es importante estudiar y analizar métodos o modelos que ayuden a mejorar esta estimación. En la literatura, son varios los métodos desarrollados para estimar los Q_{ins} a partir de los Q_{md} . Desde el punto de vista empírico, hay dos tipos de enfoques para estimar los máximos instantáneos a partir de los caudales medios. El primer tipo de enfoque establece una relación entre ambos caudales utilizando las características fisiográficas de la cuenca y el segundo tipo de enfoque calcula el instantáneo a partir de una secuencia de caudales medios diarios. En estudios recientes, como en el de Fathzadeh, Jaydari, & Taghizadeh-Mehrjardi (2017), se han comprobado métodos de Machine Learning (ML) que han aumentado la precisión en la estimación de los Q_{ins} , mejorando así los resultados obtenidos con las fórmulas empíricas existentes.

1.2 JUSTIFICACIÓN DE LA INVESTIGACIÓN

Como ya se indicó en el apartado anterior, son muchas las razones por las cuales se necesitan modelar los procesos lluvia-escorrentía, en concreto la modelación de los caudales. La razón principal son las limitaciones existentes en las técnicas de medición hidrológica, disponiéndose solamente de un rango limitado de mediciones o registros en el espacio y en el tiempo. Por lo tanto, se necesita de un medio para extrapolar esas mediciones en el espacio y en el

tiempo, particularmente en las cuencas no aforadas (donde los datos no están disponibles) y en el futuro (donde las mediciones no son posibles) para evaluar el posible impacto del cambio hidrológico futuro. Los modelos lluvia-escorrentía son muy útiles para el completado de series históricas de caudales naturales a partir de series climáticas, y para la estimación de caudales en futuros escenarios climáticos. Los datos de precipitación y temperatura suelen ser más abundantes que los de caudal y su recopilación es más sencilla y tiene un menor coste (OMM, 2011). En toda cuenca hidrográfica los datos de caudal son de primordial importancia para las tareas de planificación y gestión de los recursos hídricos. La estimación y evaluación de los caudales es esencial para la gestión sostenible de los recursos hídricos y los modelos proporcionan un medio de extrapolación o predicción cuantitativa, pudiendo estos ser útiles en la toma de decisiones (Bever, 2011). Por lo tanto, encontrar modelos que realicen estimaciones de caudales lo más precisas posibles es fundamental a la hora de tomar decisiones. Sin embargo, la estimación precisa de los caudales consecuentes de un proceso de lluvia-escorrentía a escala de cuenca es extremadamente difícil debido a la gran variabilidad espacial y temporal de las características de la cuenca y de los patrones climáticos, así como de una incompleta comprensión de los complejos procesos físico subyacentes (Srivastava et al., 2006). La complejidad hidrológica de una cuenca queda claramente reflejada en las diferentes fases de la serie temporal de caudales, existiendo caudales muy altos y caudales muy bajos. Por lo que siempre ha sido un gran reto para los modelos hidrológicos la representación adecuada de todas las fases de caudales con el mismo conjunto de parámetros del modelo (Madsen, 2000). La utilización de un modelo en el que los caudales muy altos simulados subestiman a los caudales observados conlleva un riesgo de sufrir inundaciones; y en el caso de emplear un modelo en el que los caudales muy bajos simulados sobreestiman a los caudales observados conlleva un problema en el suministro de agua. Otra problemática a tener en cuenta en la modelación de los caudales en zonas de alta montaña, es la correcta modelación de los procesos nivales y la estimación de los errores sistemáticos en la medición de precipitación sólida. La modelación del fenómeno de acumulación-fusión de la nieve es esencial para desarrollar una explotación óptima de los embalses de cabecera, así como realizar la previsión de posibles avenidas motivadas por una rápida fusión de la nieve.

Por todo ello, en la presente tesis se han utilizado y analizado el comportamiento de tres modelos determinísticos para la simulación de caudales. Por un lado, un modelo empírico como las RNAs, un modelo conceptual y físicamente basado como es el modelo hidrológico SWAT (Soil and Water Assessment Tool), y por último, el clásico modelo hidrológico conceptual de Témez al que se le agrega un modelo de nieve. SWAT es un modelo muy empleado en la actualidad y se ha utilizado ampliamente para la estimación de series temporales de caudales. SWAT requiere una gran cantidad de datos espaciales y temporales, así como de parámetros de entrada con un amplio rango de valores y con complejas interacciones entre ellos; haciendo que la parametrización de este modelo y de su proceso de calibración sean tareas complejas. En cambio, los datos de entrada y parámetros necesarios para las RNAs son mucho más reducidos, simplificando así las tareas de entrenamiento de estos modelos. Además, las RNAs cuentan con la ventaja particular de que pueden construirse y ser entrenadas para aprender las relaciones existentes en el proceso hidrológico de lluvia-escorrentía sin la necesidad de tener un conocimiento a priori de las características físicas de este proceso. Estas características han hecho que las RNAs hayan ido ganando interés entre los hidrólogos, convirtiéndose en una interesante alternativa para simular procesos hidrológicos complejos simplemente conectando las entradas y salidas del modelo a través de funciones matemáticas sin la necesidad de conocer la relación existente con las características de la cuenca (Singh, Imtiyaz, Isaac, & Denis, 2012). Debido a que los caudales varían entre cuencas hidrográficas por las diferentes características fisiográficas, climáticas y paisajísticas, para evaluar la capacidad de ambos modelos en la simulación de caudales medios diarios, se lleva a cabo la experimentación en dos cuencas con condiciones climáticas diferentes. Un mismo modelo puede mostrar diferentes rendimientos cuando se aplican en diferentes cuencas. Además, con diferentes estructuras de un modelo puede variar su rendimiento en la misma cuenca de estudio. Por lo tanto, es importante determinar qué modelos son los más adecuados para una aplicación particular y si un modelo más sencillo es suficiente, no será necesario utilizar uno más complejo (Zhang et al., 2016). Y debido a que el flujo de agua en una cuenca está intrínsecamente sujeto a episodios extremos de flujos altos y bajos, la eficiencia de

los modelos además es analizada en los diferentes rangos de caudal, desde caudales muy altos a caudales muy bajos, utilizando las curvas de duración de caudales (CDCs) para este propósito. Por otro lado, con el propósito de mejorar la simulación de caudales en cuencas de alta montaña, donde la componente nival juega un papel importante, se ha desarrollado un modelo de nieve, el cual ha sido aplicado a una cuenca nival. El modelo desarrollado, ha sido llamado STM (Snow-Témez model), y es un modelo híbrido formado por la combinación del clásico modelo conceptual de Témez (Témez, 1977) con el modelo de nieve TIM (The temperature-index snowmelt model) (Hock, 2003; Irannezhad, Ronkanen, & Kløve, 2015). El modelo STM tiene incorporado dos parámetros de corrección para corregir los datos de precipitación recogidos en los pluviómetros/nivómetros. Dicho parámetros ayudan a mejorar los resultados de la simulación de caudal, y permiten evaluar la existencia de un *under-catch* en las mediciones de precipitación.

Tal y como se explicó en el apartado anterior 1.1.2, también es importante conocer el valor de los Q_{ins} en las cuencas. Sin embargo, no siempre estos datos están disponibles, por lo que en estos casos es necesaria su estimación. La estimación de la frecuencia y la magnitud del Q_{ins} es fundamental para la gestión del riesgo de inundación y también para el diseño de estructuras hidráulicas (Ding & Haberlandt, 2017). Una estimación correcta de los Q_{ins} es crucial para reducir las consecuencias derivadas de las avenidas, especialmente en los países mediterráneos. Por ello la importancia de estudiar y analizar diferentes técnicas que reduzcan las incertidumbres asociadas a la estimación de los Q_{ins} . En la segunda parte de la presente tesis, se analiza el rendimiento de diferentes fórmulas empíricas y se comparan los resultados obtenidos en la estimación de los Q_{ins} con los obtenidos empleando diferentes técnicas de ML, como las RNAs, los sistemas adaptativos de inferencia neuro-difusa (ANFIS), las máquinas de vector soporte (SVM) y las redes extreme learning machines (ELM). Todos estos métodos se basan en datos diarios. Como la única forma de obtener caudales instantáneos con precisión es medirlos, si estos no se han medido, cualquier intento de obtener el caudal instantáneo después dará como resultado un valor aproximado. Aunque la relación entre el Q_{md} y el Q_{ins} es lógicamente variable de una avenida a otra, en la mayoría de las cuencas, esta relación suele ser más o menos constante o, al menos, fluctúa dentro de un rango relativamente estrecho

de valores (CEDEX, 2011). Esto ha llevado a esta investigación a la aplicación de técnicas empíricas para calcular los valores del Q_{ins} a partir de los valores conocidos de Q_{md} .

Finalmente en la presente tesis se realiza una combinación y ampliación de los experimentos llevados a cabo inicialmente. En primer lugar se obtienen los caudales medios diarios en una cuenca y a partir de ellos se obtienen los instantáneos. En las cuencas donde la longitud de las series de datos de caudales medios observados es menor a la necesaria, un modelo hidrológico de simulación continúa, como es SWAT, puede ser utilizado para aumentar la longitud de la serie de datos (Lee, Heo, Lee, & Kim, 2017). La serie de caudales que se obtienen del modelo hidrológico son valores medios relativos a una determinada escala temporal, en este caso diaria. El modelo SWAT puede simular a escala diaria pero no puede hacerlo a escala horaria o a una escala más minuciosa tal y como sería necesario para simular los Q_{ins} . A partir de esta serie de caudales se extraen los datos de caudales medios, al ser valores medios en ningún caso se puede obtener de ellas los Q_{ins} . Por lo que resulta necesario el empleo de otras técnicas para la obtención de los máximos instantáneos. En la presente tesis se estudian y aplican diferentes métodos para calcular los Q_{ins} a partir de los máximos Q_{md} obtenidos en SWAT.

1.3 OBJETIVOS

Esta investigación parte del creciente interés por encontrar modelos que simulen y estimen los caudales de las cuencas hidrográficas con mayor precisión, además del gran reto que supone para los modelos la representación adecuada de todas las fases de caudales. Los datos de caudal son de primordial importancia para la planificación y gestión de los recursos hídricos, y la precisión de su estimación es muy importante para la toma de decisiones. Por otro lado, la correcta estimación de los caudales máximos instantáneos es crucial para reducir las consecuencias de las inundaciones.

En primer lugar, la presente tesis se centra en analizar y evaluar modelos que simulan el caudal en dos cuencas con contrastadas condiciones climáticas. Seleccionar el modelo apropiado para simular el caudal en una cuenca hidrográfica es un desafío clave, y analizar el rendimiento de estos modelos en

diferentes cuencas climáticas podría ayudar a los investigadores a aplicar el modelo más adecuado en cada caso. El modelado del proceso lluvia-escorrentía es llevado a cabo por un lado con un modelo conceptual físicamente basado (SWAT) y por otro lado con un modelo empírico de caja negra (RNA). Por otro lado, para mejorar la simulación de los caudales en cuencas con nieve, se desarrolla el modelo STM, combinando un modelo pluvial y uno nival, al que se incorporan dos parámetros de corrección de la precipitación.

En segundo lugar, la tesis analiza el comportamiento de diferentes métodos para la estimación de los caudales instantáneos. En concreto, se analizan diferentes métodos en catorce cuencas españolas que cubren la diversidad de condiciones de torrencialidad. Por último, en una cuenca seleccionada se realiza la simulación de su caudal medio diario y se aplican cuatro técnicas de Machine Learning para el cálculo de los caudales máximos instantáneos.

En relación a lo expuesto anteriormente se exponen los siguientes objetivos generales:

1. Evaluar y comparar el rendimiento de los modelos SWAT y RNA en la estimación de los caudales medios diarios.
2. Desarrollar un modelo hidrológico que permita aproximar el efecto de la componente nival, analizar su comportamiento en una cuenca y su sensibilidad a la aplicación de factores correctores de la precipitación.
3. Evaluar diferentes métodos, fórmulas empíricas y modelos de machine learning para estimar los caudales máximos instantáneos.
4. Analizar el comportamiento del uso combinado de SWAT y machine learning para la estimación de caudales máximos instantáneos.

En la consecución de estos objetivos generales se establecen los siguientes objetivos específicos:

- Evaluar la precisión y el rendimiento de los modelos de estimación de caudales medios diarios para cada evento de descarga importante. Es decir, analizar el rendimiento de estos modelos en la estimación de los caudales en las diferentes fases del hidrograma, desde los caudales pico hasta los caudales

- muy bajos. Además de evaluar el comportamiento de cada modelo en cuencas con características climáticas diferentes.
- Identificar la combinación óptima de modelos geoestadísticos e hidrológicos para aproximar series históricas de caudales a partir de datos climáticos. Realizar una valoración del *under-catch* de precipitación sólida y líquida que permite minimizar los errores al estimar caudales. Identificar y analizar el patrón de precipitación (distribución entre precipitación sólida y líquida y gradientes de precipitación con la altura).
 - Identificar la técnica que obtiene resultados más precisos en la estimación de los caudales máximos instantáneos a partir de datos diarios. Comprobar la utilidad de aplicar las nuevas técnicas de machine learning frente a los métodos clásicos.
 - Analizar la utilidad para la estimación de los caudales instantáneos del uso combinado de SWAT y las técnicas de machine learning. Evaluación de SWAT para obtener los caudales máximos diarios y a continuación evaluar una técnica de aprendizaje automático para la obtención de los instantáneos.

El trabajo desarrollado en esta tesis aporta varias contribuciones originales. En el caso de la utilización de los modelos SWAT y ANN para simular caudales, son pocos los estudios que han comparado ambos modelos para la estimación diaria de caudal, no existiendo ningún trabajo de este tipo en la España Peninsular. Otro aporte original es la combinación del modelo TIM y el modelo Témez para la simulación de caudales en cuencas con nieve, incorporando unos factores correctores que permiten evaluar la existencia de la problemática llamada *under-catch* existente en los registros de la precipitación. También es novedosa la aplicación de los modelos ANN y ANFIS en la estimación de caudales máximos instantáneos en las diferentes zonas de estudio seleccionadas. Hasta donde se tiene conocimiento, el trabajo de combinación de SWAT junto con cuatro técnicas de ML, como son ANN, ANFIS, SVM y ELM, para la estimación de caudales máximos instantáneos no se ha realizado en ningún estudio previo.

Los resultados encontrados ayudarán a ingenieros o a otros investigadores en sus tareas de modelación y estimación de caudales para tareas de diseño de estructuras o/y gestión y planificación de recursos hídricos. Los modelos de simulación de caudales pueden ser utilizados para completar datos incompletos

en las series de caudales observados. Además, los resultados obtenidos en el estudio de estimación de caudales instantáneos pueden ayudar a predecir los caudales instantáneos en cuencas no aforadas. Para ello se pueden utilizar técnicas de inteligencia artificial, como clustering, para identificar cuencas homogéneas cercanas que si dispongan de datos, y entrenar con los datos de estas cuencas cercanas los modelos para predecir los caudales a calcular.

1.4 ESTRUCTURA DE LA TESIS

La estructura general de esta memoria de tesis se presenta en seis capítulos y un apéndice. Tras la introducción del **Capítulo I**, en el **Capítulo II** se presenta los antecedentes y el estado del arte sobre los modelos de simulación de caudales empleados, así como de las técnicas de estimación de caudales máximos instantáneos. El **Capítulo III** se describe las zonas de estudio y la metodología llevada a cabo para alcanzar los objetivos. En el **Capítulo IV** se exponen las tres publicaciones que conforma el compendio de publicaciones de esta tesis doctoral, una cuarta publicación que se encuentra bajo revisión, y se presenta una síntesis de los resultados obtenidos y la discusión de los mismos. En el **Capítulo V** se exponen las conclusiones y las futuras líneas de la investigación. El **Capítulo VI** recoge las referencias bibliográficas citadas a lo largo de todo este documento. Finalmente, en el **Apéndice**, se presenta toda la información referente a la calidad de las tres publicaciones publicadas que conforman la presente tesis.

II – ANTECEDENTES Y ESTADO DEL ARTE

II – ANTECEDENTES Y ESTADO DEL ARTE

En este capítulo se presenta la revisión bibliográfica realizada, mostrando el contexto teórico en el que se apoya este trabajo. Por una parte, se analiza el estado del arte referente a la modelación hidrológica, centrándose en el modelado de series temporales de caudales. En segundo lugar, se realiza un repaso del estado del arte y antecedentes de la estimación de caudales máximos instantáneos.

2.1 MODELACIÓN LLUVIA-ESCORRENTÍA: MODELADO DE SERIES TEMPORALES DE CAUDALES EN CUENCAS

Los modelos hidrológicos a escala de cuenca se utilizan para comprender las interacciones dinámicas entre el clima y la hidrología de la superficie terrestre, y buscan representar los procesos involucrados en la distribución de la lluvia y la generación de caudales en una cuenca. La determinación de la relación entre la lluvia y la escorrentía en una cuenca es uno de los problemas más importantes a los que se enfrentan los hidrólogos e ingenieros. Es bien conocido, que esta relación es altamente no lineal y compleja. Además de la lluvia, la escorrentía depende de numerosos factores, como la humedad inicial del suelo, los usos del suelo, la geomorfología de la cuenca, la evaporación, la infiltración, etc. Realizar estimaciones precisas del proceso lluvia-escorrentía y de los caudales consecuentes en una cuenca es extremadamente difícil debido a la tremenda variabilidad espacial y temporal de las características de la cuenca y de los patrones climáticos, y por una comprensión incompleta de los complejos procesos físicos subyacentes (Srivastava et al., 2006).

El modelado hidrológico tiene una larga historia. Su comienzo se puede remontar al desarrollo de la ingeniería civil en el siglo XIX para el diseño de carreteras, canales, sistemas de drenaje, presas, puentes, y sistemas de alcantarillado y de suministro de agua. Hasta mediados de la década de 1960, la modelización hidrológica implicó principalmente el desarrollo de conceptos, teorías y modelos para representar los mecanismos individuales involucrados en el ciclo hidrológico, tales como la infiltración, la evaporación, el flujo superficial, o

el flujo base (Singh & Woolhiser, 2002). Una aceleración extensa de nuevos descubrimientos en el modelado de la precipitación-escorrentía surgió con la revolución digital de la década de 1960, cuando el desarrollo de los modelos fue de la mano con el aumento de la potencia de cálculo de los ordenadores. Este gran avance de los ordenadores hizo posible la integración de modelos de diferentes componentes del ciclo hidrológico y por lo tanto la simulación de prácticamente la totalidad de una cuenca. Surge así el primer intento de modelar virtualmente todo el ciclo hidrológico con el Stanford Watershed Model-SWM (ahora llamado HSPF) de Crawford & Linsley (1966). A partir de la década de 1970 el poder de los ordenadores fue aumentando exponencialmente y, como resultado, los avances en la hidrología de cuencas se fueron produciendo a un ritmo sin precedentes. Se desarrollaron numerosos modelos, entre los que se encuentran el modelo SSARR (Rockwood, Davis, & Anderson, 1972), el modelo HYOM (Williams & Hann, 1973), el modelo de Sacramento (Burnash, Ferral, & McGuire, 1973), el modelo de tanque (Sugawara, Ozaki, Wantanabe, & Katsuyama, 1976), TOPMODEL (Beven & Kirkby, 1979), CREAMS (Knisel, 1980), HEC-1 (Hydrologic Engineering Center [HEC], 1981), SHE (Systeme Hydrologique europeen) (Abbott, Bathurst, Cunge, O'Connell, & Rasmussen, 1986), y el modelo ARNO (Todini, 1996). Todos estos modelos han mejorado significativamente desde entonces.

Algunos de los primeros modelos tenían ciertas lagunas, no incluían ciertos procesos importantes como la evapotranspiración o el flujo subsuperficial, que los hacían incompletos. Y aquellos modelos que sí que podían incluir más procesos, no los incorporaban con una suficiente resolución espacial como para ser realmente eficaces en la simulación de procesos de una cuenca (Arnold, Srinivasan, Muttiah, & Williams, 1998). Debido al aún limitado poder de cálculo y a las limitadas bases de datos espaciales, los primeros modelos hidrológicos trataban los parámetros de entrada como agregados para toda la cuenca e ignoraban la variabilidad espacial de los procesos hidrológicos (Zhang et al., 2016). En las últimas dos décadas con los grandes avances en los hardware y en softwares, que incluyen una mayor velocidad y almacenamiento, las herramientas proporcionadas por los Sistemas de Información Geográfica (SIG) y la mayor disponibilidad de bases de datos espacialmente distribuidos han permitido un gran desarrollo de los modelos distribuidos y físicamente basados, logrando que

la simulación de grandes áreas sea factible, pudiendo incorporar al modelo todos los parámetros necesarios para simular todos los procesos del ciclo hidrológico.

Además, las grandes preocupaciones actuales como, la gestión del agua en las regiones áridas, las inundaciones a gran escala, el impacto del cambio climático o los impactos de la gestión del suelo, han motivado el gran desarrollo de modelos que simulen grandes áreas. El reto de estas últimas décadas era desarrollar modelos a escala de cuenca que: (i) fueran computacionalmente eficientes; (ii) permitieran un considerable detalle espacial; (iii) las entradas requeridas estuvieran fácilmente disponibles; (iv) fuesen de tiempo continuo; (v) tuvieran la capacidad de simular diferentes escenarios de gestión; y (vi) dieran resultados razonables (Arnold & Fohrer, 2005). Un modelo ampliamente utilizado en la última década y que dio respuesta a estas necesidades fue el modelo SWAT (Arnold et al., 1998). SWAT fue desarrollado por el Servicio de Investigación Agrícola (ARS) de los EE.UU y cuenta con la ventaja particular de que es un software libre. SWAT es la última generación de una larga línea de modelos desarrollados por el Departamento de Agricultura de los EE.UU. La última versión del modelo es SWAT2012. Es un modelo conceptual, semidistribuido y físicamente basado, y actualmente es uno de los modelos hidrológicos más populares a escala de cuenca (Grusson, Anctil, Sauvage, & Sánchez Pérez, 2017). SWAT ha sido utilizado exitosamente en todo el mundo con diferentes propósitos, tales como la evaluación de recursos hídricos, evaluación de la calidad del agua, evaluación de los cambios del uso del suelo, así como para la evaluación del impacto del cambio climático (Krysanova & White, 2015). Se ha utilizado ampliamente para el modelado del proceso lluvia-escorrentía, siendo muchos los estudios previos que han demostrado la capacidad de SWAT para modelar la escorrentía bajo diferentes condiciones ambientales (Cibin, Sudheer, & Chaubey, 2010; Gassman, Reyes, Green, & Arnold, 2007; Rahman et al., 2013; Srivastava et al., 2006; Wang, Yang, Wang, Xu, & Xue, 2014). Sin embargo, SWAT se ha aplicado escasamente en España (Conan, de Marsily, Bouraoui, & Bidoglio, 2003; Malagò, Pagliero, Bouraoui, & Franchini, 2015; Raposo, Dafonte, & Molinero, 2013; Senent-Aparicio, Pérez-Sánchez, Carrillo-García, & Soto, 2017).

Todos los modelos comentados anteriormente están basados en un enfoque físico y requieren una clara definición de los datos de entrada al modelo, de las leyes físicas que rigen el comportamiento de los procesos hidrológicos de la

cuenca y una definición de las condiciones iniciales y de contorno. Estos modelos tienden a ser computacionalmente exigentes, requiriendo numerosos datos y un conocimiento del funcionamiento de la cuenca. Además, muchos de los datos necesarios no están disponibles para todas las cuencas. Para abordar este problema, muchos investigadores comenzaron a aplicar la Inteligencia Artificial (IA), como las redes neuronales artificiales, las máquinas de vector soporte, la lógica difusa o los algoritmos genéticos. Durante la última década, son numerosos los trabajos donde los investigadores han demostrado con éxito como la IA puede ser utilizada para aplicaciones hidrológicas en cuencas, tales como la predicción de inundaciones, modelación de la precipitación-escorrentía, o modelos de predicción de la calidad del agua. Algunas de las aplicaciones de IA encontradas en la literatura son: Olyaie, Banejad, Chau, & Melesse (2015) comparan tres técnicas de inteligencia artificial, como RNAs, ANFIS y redes wavelet (WANN), para estimar la carga de sedimentos en suspensión en dos aforos en EE.UU.; Amirhossien, Alireza, Kazem, & Mohammadbagher (2015) emplean un modelo de RNA para simular la escorrentía en una cuenca de Iran; Babbar & Babbar (2017) aplican modelos de RNAs y SVMs para predecir la calidad del agua basándose en un índice de contaminación.

El desarrollo de las redes neuronales artificiales comenzó hace aproximadamente 70 años (McCulloch & Pitts, 1943), inspirado en el deseo de comprender el cerebro humano y emular su funcionamiento. A finales del siglo XX, las RNAs experimentaron un gran resurgimiento debido al gran desarrollo de algoritmos más sofisticados y al gran desarrollo de las herramientas de computación. Se produjo un gran crecimiento en el interés de este mecanismo computacional desde que Rumelhart, Hinton, & Williams (1985) redescubrieron un marco teórico matemáticamente riguroso para las redes neuronales, como fue el algoritmo de entramiento de back-propagation. A partir de entonces, las RNAs han encontrado aplicaciones en áreas tan diversas como la física, la ingeniería biomédica, las finanzas, y otras.

Matemáticamente, una RNAs se puede tratar como un aproximador universal. La capacidad de identificar una relación a partir de unos patrones dados hace posible que las RNAs resuelvan problemas complejos a gran escala, como el reconocimiento de patrones, modelado no lineal, clasificación, asociación y otros, teniendo todos aplicación en la hidrología (ASCE, 2000a). Desde

principios de los noventa, las RNAs se han utilizado con éxito en áreas relacionadas con la hidrología, como en el modelado de precipitación y escorrentía, predicción de caudales, modelación de aguas subterráneas, calidad del agua, política de gestión del agua, predicción de precipitaciones, series temporales hidrológicas y operaciones de los embalses. Las ventajas encontradas en las RNAs que las convirtieron en atractivas para las aplicaciones de recursos hídricos e hidrología fueron su habilidad para (i) extraer la relación existente entre las variables de entrada y de salida de un proceso, sin considerar las leyes físicas involucradas; (ii) funcionar de forma adecuada incluso cuando los conjuntos de datos de entrenamiento contienen ruido y errores; (iii) adaptarse bien a las circunstancias cambiantes; (iv) una vez entrenados son relativamente fáciles de utilizar (ASCE, 2000a).

En numerosos trabajos encontrados en la literatura (Hsu, Gupta, & Sorooshian, 1995; Wu, Han, Annambhotla, & Bryant, 2005; Kumar, Raghuwansh, & Singh, 2009) se han encontrado que las complejidades en los procesos físicos y de las relaciones no lineales, como los procesos de precipitación-escorrentía o la evapotranspiración, se prestaban al modelado con RNAs. Pasando estos modelos de RNAs a ser considerados como una alternativa a los modelos físicamente basados debido a su sencillez a la hora de recopilar datos detallados de las cuencas a estudiar. La principal ventaja de las RNAs frente a los métodos convencionales es la capacidad de modelar los procesos físicos sin la necesidad de disponer de información detallada (Daniel et al., 2011). Esta característica convierte a las RNAs en efectivas herramientas para modelar procesos hidrológicos complejos (Talebizadeh & Moridnejad, 2011). Las RNAs se han utilizado en numerosos estudios para modelar el proceso lluvia-escorrentía y el consecuente caudal (Dawson & Wilby, 1998; Hsu et al., 1995; Shiau & Hsu, 2016; Wang, Guo, Xiong, Liu, & Liu, 2015).

Por lo tanto, los modelos SWAT y RNA se han utilizado en muchos estudios para la estimación de caudales, pero estos trabajos se centran en la evaluación y comparación del rendimiento de estos modelos individualmente frente a otros modelos hidrológicos. Sin embargo, pocos trabajos han comparado el rendimiento de ambos modelos en una misma cuenca de estudio. Los pocos trabajos de este tipo encontrados hasta el momento en la literatura son: Demirel, Venancio, &

Kahya (2009); Kim et al. (2015); Makwana & Tiwari (2017); y Srivastava et al. (2006).

En cuanto a la modelación de cuencas de cabecera con nieve, en la presente tesis se presenta el modelo STM, un híbrido entre el modelo TIM (Hock, 2003; Irannezhad et al., 2015) y el modelo de Témez (Témez, 1977). El modelo de Témez, que ha sido ampliamente utilizado en trabajos españoles de hidrología (p. ej., Jódar et al., 2017; Jódar & Jiménez, 2016; Murillo & Navarro, 2011), es utilizado para el modelado puramente pluvial. Para el caso de cuencas alpinas con procesos nivales, el modelo de Témez no puede ser aplicado como tal. Por ello, es necesario agregar a este modelo un modelo de nieve, en este caso el modelo TIM, que reproduzca las aportaciones de caudales a la cuenca como consecuencia del deshielo. Las series de precipitación sólida, datos de entrada al modelo de nieve, muestran un *under-catch* (fenómeno de la captura insuficiente de lluvia por parte de los pluviómetros). Este fenómeno de *under-catch* es el responsable de que exista un importante sesgo entre los valores reales precipitados y las medidas reales de precipitación. El *under-catch* es especialmente significativo en condiciones de viento y depende de algunos procesos físicos relevantes que afectan el error sistemático de la medición de la precipitación en los medidores (Goodison, Louie, & Yang, 1998; Groisman y Legates, 1994). Desde hace mucho tiempo se reconoce que estos errores afectan a todos los tipos de pluviómetros (Yang et al., 1995) y se asocian principalmente con la deformación del campo de viento por encima del orificio del medidor, pérdidas por humectación y evaporación en las paredes internas del medidor y salpicaduras de gotas de lluvia o nieve dentro o fuera del aparato (Goodison et al., 1998; Sevruk, 1982). La agregación de todos estos procesos usualmente produce una subestimación de la medida de precipitación real (Adam & Lettenmaier, 2003; Groisman & Legates, 1994; Sevruk, 1982). Son numerosos los autores (Goodison et al., 1998; Groisman & Legates, 1994; Yang et al., 1995) que han reconocido la necesidad de corregir estos errores sistemáticos, especialmente para la precipitación sólida, por sus efectos sobre la hidrología y en los estudios climatológicos. En varios estudios encontrados en la literatura se realiza un análisis de los efectos de corregir la precipitación sobre la escorrentía y el balance hídrico en una fase previa al modelado (Fekete, Vörösmarty, Roads, & Willmott, 2004; Stisen et al., 2012). Solo algunos de ellos se centran en la corrección de la precipitación a escala de cuenca, por ejemplo, Valery,

Andréassian, & Perrin (2009) y Sherestha et al. (2014) realizaron la corrección del *under-catch* de nieve utilizando unos parámetros optimizados que minimiza la diferencia entre el caudal observado y el simulado por el modelo.

2.2 ESTIMACIÓN DE CAUDALES MÁXIMOS INSTANTÁNEOS

Los métodos para estimar el caudal máximo instantáneo basados en datos diarios medios han sido estudiados por los hidrólogos durante este último siglo. Para abordar este problema, básicamente se han empleado dos enfoques diferentes. El primer enfoque incluye métodos que establecen una relación entre el Q_{ins} y el Q_{md} utilizando las características fisiográficas de la cuenca. El segundo enfoque calcula el Q_{ins} a partir de una secuencia de datos de caudales medios diarios.

En el primer enfoque se incluye el método de Fuller (1914). Fuller realizó uno de los primeros estudios relacionados con la obtención del Q_{ins} a partir del máximo caudal medio diario (MQ_{md}) y del área de drenaje de la cuenca. En este enfoque también están incluido el método de Silva & Tucci (1998), destinado a obtener un modelo que permitiera estimar un coeficiente que relacionara el Q_{ins} y Q_{md} utilizando ajustes gráficos de cada variable fisiográfica involucrada y un análisis de regresión múltiple. Los autores también intentaron utilizar el tiempo de concentración, en lugar de las características fisiográficas de la cuenca. Sin embargo, su estudio no fue concluyente y no propusieron una ecuación final para el coeficiente de caudal máximo. Taguas et al., (2008) propusieron una ecuación para estimar el Q_{ins} a partir del Q_{md} , el área de drenaje y la precipitación anual media en el sureste de España.

Siguiendo el método de Fuller (1914), muchos otros autores han presentado fórmulas empíricas que relacionan el Q_{ins} con el Q_{md} y con el área de la cuenca para diferentes regiones del mundo (Gray, 1973; Tucci, 1991). En el trabajo de Fill & Steiner (2003) se recogen algunas de estas fórmulas. En España, dentro del ámbito del Sistema Nacional de Cartografía de Zonas Inundables (SNCZI), un instrumento de apoyo a la gestión del espacio fluvial y la prevención de riesgos, el MAPAMA encargó al CEDEX un mapa de los caudales máximos asociados a distintas probabilidades de recurrencia en la red de ríos que gestiona a través de las distintas Confederaciones Hidrográficas. El CEDEX en su trabajo de

elaboración del mapa de caudal máximos (CEDEX, 2011) adaptó la fórmula de Fuller a trece regiones, cubriendo así todo el área de la España peninsular, para transformar los datos de caudales diarios en instantáneos. En este trabajo, se realizó una calibración regional de los parámetros de la fórmula de Fuller para cada una de las trece demarcaciones estudiadas.

Entre los métodos que utilizan el segundo enfoque, hay dos procedimientos pioneros propuestos por Jarvis (1936) y por Langbein (1944) y descritos por Linsley, Kohler, & Paulhus, (1949), y posteriormente, el método propuesto por Sangal (1983). Jarvis (1936) analizó una gran cantidad de datos de caudales instantáneos y máximos diarios, concluyendo que los datos no permitían conclusiones generalizadas. El método de Langbein (1944) presenta un diagrama de la relación entre el Q_{ins} y MQ_{md} como una función de la relación del caudal máximo con el caudal del día anterior y con el del día posterior. Sangal (1983) propone una ecuación basada en un hidrograma triangular, que calcula el Q_{ins} a partir de datos de caudales medios diarios de tres días consecutivos entre los que se encuentra el día en el que se produjo el instantáneo. Este método condujo a resultados con una precisión razonable, aunque sesgado hacia abajo para cuencas pequeñas. Y en grandes cuencas, con áreas mayores de 1000 km², los resultados basados en el método de Sangal indicaron que había una tendencia a sobreestimar los Q_{ins} . Esto motivó a Fill & Steiner (2003) a revisar la metodología de Sangal (1983) y proponer una mejora a su ecuación.

Si no existe una relación lineal entre las variables dependientes (p.e., el caudal máximo instantáneo) y las variables independientes (p.e., las características fisiográficas de la cuenca), la inteligencia artificial puede ser aplicada para capturar esas relaciones no lineales y obtener un modelo de predicción. De acuerdo con recientes estudios de la literatura (Fathzadeh et al., 2017), nuevos métodos han incrementado la precisión en la estimación del Q_{ins} a través de la aplicación de técnicas de machine learning en la última década.

En el apartado 2.1, ya se definieron algunas de las ventajas de utilizar las RNAs. Mustafa, Isa, & Rezaur (2012) examinaron la efectividad de las RNAs en la resolución de diferentes problemas hidrológicos y concluyeron que el modelo de redes neuronales era ventajoso en comparación con otras técnicas convencionales. Las RNAs tienen la capacidad de obtener la relación entre la variable predictora y

la variable a estimar de un proceso (ASCE, 2000b), en este caso el MQ_{md} y Q_{ins} , respectivamente.

ANFIS es otra poderosa técnica para modelar un sistema no lineal, e integra lógica difusa en las redes neuronales. El modelo ANFIS es una fusión de RNA y del sistema de inferencia difuso (FIS, por sus siglas en inglés), y posee las ventajas de ambos sistemas. Los modelos ANFIS tienen la capacidad de aprendizaje de las RNAs y se adaptan a los entornos cambiantes, y la ventaja de los FIS de generar sistemáticamente reglas difusas a partir de la información dada al modelo, inputs y targets (Abraham, Köppen, & Franke, 2003; Hamaamin, Nejadhashemi, Zhang, Giri, & Woznicki, 2016). Esta combinación permite que un FIS aprenda de los datos para crear modelos, y que sea un modelo eficiente para determinar el comportamiento de sistemas dinámicos complejos definidos de forma imprecisa (Kim & Kasabov, 1999). Por lo tanto, ANFIS también ha sido aceptado como una técnica alternativa eficiente para el modelado y la predicción en hidrología (Emamgholizadeh, Moslemi, & Karami, 2014). Algunos de los trabajos de la literatura que han aplicado ANFIS en hidrología son Dastorani, Moghadamnia, Piri, & Rico-Ramirez (2010) y Seckin (2011).

Aunque ANN y ANFIS tienen grandes ventajas, también es necesario comentar ciertas desventajas (Rezaei, Rahmati, & Modarress, 2017; Tu, 1996), tales como: (i) las RNAs son una caja negra y no aclaran la relación funcional entre los valores de entrada y salida; (ii) una red neuronal debe ser entrenada para cada problema para obtener la arquitectura adecuada, y esto requiere mayores recursos computacionales; y (iii) ANFIS es más complicado que FIS y no está disponible para todas las opciones de FIS.

En la literatura son pocos los trabajos que comparan modelos de machine learning con las fórmulas empíricas. Shabani & Shabani (2012) aplican RNAs para estimar el Q_{ins} a partir del MQ_{md} y compararon sus resultados con los métodos de Fuller (1914), de Sangal (1983) y de Fill & Steiner (2003). Un año después Dastorani, Koochi, Darani, Talebi, & Rahimian (2013) además de las redes neuronales aplicaron ANFIS para comprobar su eficiencia frente a las fórmulas empíricas, y concluyeron que ANFIS aumentaba la precisión de la estimación de los caudales máximos instantáneos.

La técnica de machine learning SVM se ha utilizado con menos frecuencia en el contexto hidrológico (Vapnik, 1998). Uno de estos trabajos es el de Misra, Oommen, Agarwal, Mishra, & Thompson (2009) que comparan el rendimiento de SVM y RNAs en la simulación de la escorrentía y de los sedimentos a escala diaria, semanal y mensual, concluyendo que SVM es una alternativa eficiente a las RNAs. La aplicación de SVM en la estimación de regresión no lineal está aumentando debido a un buen rendimiento de generalización (Cao & Tay, 2003). Posteriormente, se presentó una novedosa técnica de machine learning, las máquinas de aprendizaje extremo (ELM) (Huang, Zhu, & Siew, 2004). Como se puede ver en Huang, Huang, Song, & You (2015) la técnica de ELM se ha aplicado con éxito en análisis de datos biomédicos, visión artificial, procesamiento de imágenes y modelado y predicción de sistemas. Sin embargo, las aplicaciones de ELM para estimar caudales son escasas (Deo & Şahin, 2016; Rezaie-Balf & Kisi, 2017). No se han encontrado trabajos donde apliquen SVM y ELM para el cálculo de caudales máximos instantáneos.

Como ya se comentó en el capítulo I, la simulación SWAT se basa en una escala diaria, por lo que el modelo SWAT no puede trabajar para una escala tan minuciosa como para simular los Q_{ins} . Para abordar este problema se pueden aplicar las diferentes técnicas ya comentadas para estimar el Q_{ins} a partir de los MQ_{md} obtenidos en SWAT. Lee, Heo, Lee, & Kim (2017) evaluaron los efectos de una presa sobre la frecuencia de las inundaciones combinando una simulación SWAT y una fórmula empírica, el método de Sangal (1983), para estimar el Q_{ins} . Sin embargo, hasta donde se tiene conocimiento, SWAT aún no se ha utilizado en combinación con técnicas de machine learning para obtener los Q_{ins} .

III –METODOLOGÍA DE LA INVESTIGACIÓN

III –METODOLOGÍA DE LA INVESTIGACIÓN

El presente capítulo de Metodología de la Investigación se organiza en cuatro apartados. En el en el apartado 3.1 se describen las zonas de estudio. En el apartado 3.2 se realiza la descripción del modelo SWAT, a continuación en el apartado 3.3 se describe el modelo hidrológico STM, en el apartado 3.4 se describen las cuatro técnicas de machine learning empleadas en esta tesis (RNA, ANFIS, SVM y ELM), y por último en el apartado 3.5 se exponen las fórmulas empíricas empleadas para el cálculo de caudales máximos instantáneos.

3.1 DESCRIPCIÓN DE LAS ZONAS DE ESTUDIO

Para comparar la precisión de los modelos SWAT y RNA en la estimación de caudales diarios, dos cuencas españolas con características contrastadas fueron seleccionadas como casos de estudio, la cuenca del río Ladra (LRB), al norte de la cuenca hidrográfica del Miño-Sil, con clima atlántico, y la cabecera de la cuenca del río Segura (HSRB) con un clima mediterráneo. La Figura 1 muestra el mapa de ubicación y los modelos digitales de elevación (DEM) de estas dos cuencas hidrográficas.

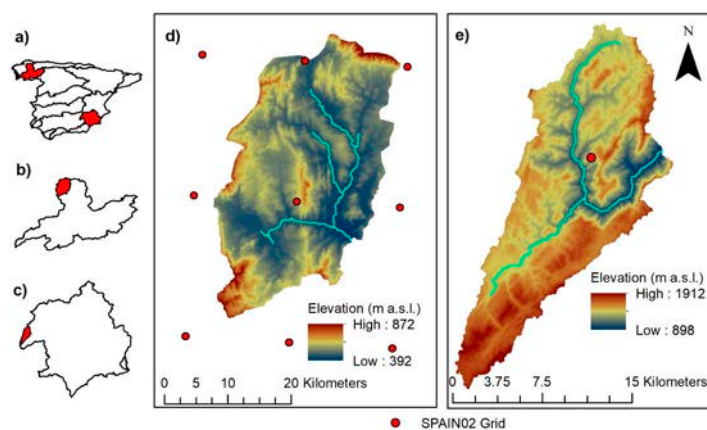


Figura 1. (a) Localización de las cuencas Miño-Sil y Segura en la España peninsular; (b) Ubicación de la cuenca LRB en la cuenca del río Miño-Sil; (c) Ubicación del cuenca HSRB en la cuenca del río Segura; (d) DEM de LRB; (e) DEM de HSRB.

En la Tabla 1 se recogen algunas de las características medias anuales de estas cuencas, como la temperatura, la precipitación y el caudal medio anual.

Tabla 1. Características de las cuencas LRB y HSRB.

Características	LRB ¹	HSRB ²
Temperatura media anual (°C)	11.2	13.2
Precipitación media anual (mm)	1218	748
Caudal medio anual (m ³ /s)	23.66	1.85

¹ De acuerdo con el periodo 1971-2007. ² De acuerdo con el periodo 1987-2007.

La cuenca del río Ladra (LRB) es un ecosistema protegido en la región atlántica de la Península Ibérica. Se encuentra en el noroeste de España dentro de la Reserva de la Biosfera llamada “Terras do Miño” (declarada reserva en el año 2002 por la UNESCO), y declarada Lugar de Importancia Comunitaria (LIC) por la UE debido a su alto valor ecológico. LRB cubre un área de 843 km² y se caracteriza por una respuesta rápida en la transformación de la lluvia a escorrentía debido a un predominantemente lecho rocoso de baja permeabilidad y una pendiente moderada. Las elevaciones oscilan entre 392 m s.n.m. en la salida de la cuenca y 906 m s.n.m. en la cabecera. Esta área de estudio se caracteriza por un clima oceánico con temperaturas suaves durante todo el año y temporadas secas de verano. La precipitación media anual es de alrededor de 1300 mm. La temperatura media anual es de alrededor de 11 °C, con un mínimo en febrero y un máximo en agosto. El caudal en la cuenca LRB es abundante y producido por sistemas persistentes del Atlántico frontal desde el oeste, que generalmente ocurren de otoño a primavera, siendo el verano la temporada más seca (Coch & Mediero, 2016). El caudal mensual medio varía desde 48 m³/s en invierno a 4 m³/s en verano; el caudal disminuye gradualmente de otoño a verano y aumenta durante el otoño. El tipo de suelo predominante es el *Cambisol Húmico* (82% del área total). La importancia de los acuíferos es mucho menor que el aporte superficial al caudal (IGME, 2017). El 35% de la superficie de la cuenca son tierras forestales, seguido de un 24% de tierras con matorrales y/o vegetación herbácea, un 23% de tierras agrícolas heterogéneas y un 18% de uso mixto.

La cuenca HSRB está ubicada en las sierras de Segura y Cazorla donde nace el río Segura. La cuenca del río Segura representa una de las zonas más áridas del área mediterránea, presentando una gran heterogeneidad en sus regímenes de

caudales (Belmar, Velasco, & Martínez-Capel, 2011). La cuenca HSRB está ubicada en la cabecera del río Segura que desemboca en el embalse de Anchuricas. Como el terreno es montañoso presenta grandes pendientes con un rango de elevación de 898 a 1912 m s.n.m.. El clima es mediterráneo con veranos muy secos y una estación lluviosa que se extiende de octubre a mayo, durante la cual se produce más del 80% de la precipitación anual. La precipitación media anual varió de 412 a 1234 mm. El tipo de suelo principal es el *Leptosol Rendzico* (88% del área total) que presenta una profundidad variable pero siempre inferior a 50 cm, pedregosidad abundante, niveles altos de carbono y buen drenaje (Senent-Aparicio et al., 2017). La cuenca se caracteriza por condiciones que permiten la infiltración de una gran cantidad de agua y suavizan la respuesta hidrológica, y las aguas subterráneas son cruciales en la hidrología de la superficie (Moral, Cruz-Sanjulián, & Olías, 2008). Durante los meses de verano, la precipitación es prácticamente inexistente, por lo que el caudal en este período proviene principalmente de las fuentes de agua subterránea (Belmar et al., 2011). Algunos acuíferos muy importantes existen en esta área, ya que la mayoría de estas cadenas montañosas están formadas de piedra caliza (Marco, 1993). El caudal mensual promedio varía entre 0.96 m³/s en septiembre y 2.97 m³/s en enero. HSRB es una zona mayoritariamente dominada por bosques que cubre aproximadamente el 61% de la cuenca, y el 19% está cubierta por vegetación de matorral mediterráneo.

Para la aplicación del modelo STM, fue necesario la selección de una cuenca alpina donde la aportación de la fusión de la nieve al caudal total de la cuenca fuera importante. Para ello, la cuenca de Canales se seleccionó como caso de estudio. Canales es una cuenca con características alpinas ubicada en Sierra Nevada en el sureste de España (Figura 2). Sierra Nevada es un macizo montañoso situado a una latitud aproximada de 37 °N, y que cuenta con más de veinte picos alineados de más de 3000 m de altitud que divide el área en dos zonas climáticas, una zona continental al norte y una zona mediterránea al sur. En Sierra Nevada se encuentra una de las estaciones de esquí más importantes de España, siendo esta la estación más meridional de Europa. La cuenca de Canales tiene una superficie de 176.3 km², se encuentra en la cara norte y es la cabecera del río Genil.

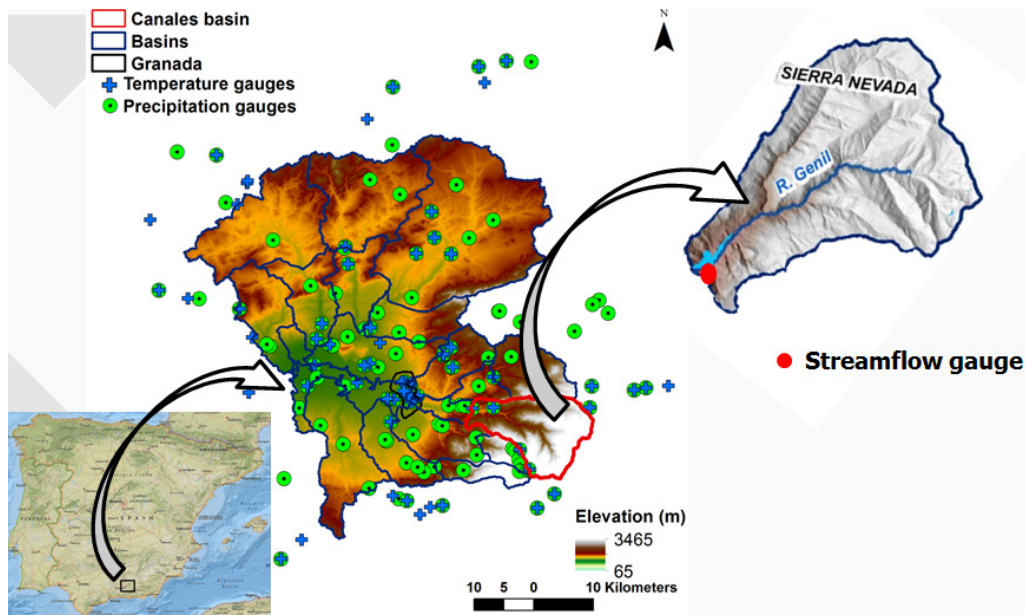


Figura 2. Localización de la cuenca de Canales dentro de la cuenca del río Genil.

Para la tarea de estimar caudales instantáneos a partir de datos medios diarios y poder seleccionar la técnica más eficiente, se aplicaron los diferentes modelos a 14 estaciones de aforos pertenecientes a 14 cuencas españolas distintas. España muestra una amplia gama de características climáticas debido a su posición entre la zona de temperatura europea y la zona subtropical. También incluye algunas de las áreas más lluviosas de Europa en el noreste, así como las más secas en el sureste, con un marcado período de sequía prolongada en verano. Las 14 cuencas se seleccionaron según varios criterios. Por un lado, se pretendía tener (i) una amplia gama de regímenes de caudales representativos de la diversidad de condiciones en la España peninsular; (ii) una serie temporal de datos lo suficientemente larga (más de 30 años) en estaciones de aforo ubicadas en cuencas en régimen natural; y por último, (iii) cuencas con áreas que no excedieran los 1000 km².

Como se muestra en la Figura 3, las cuencas utilizadas en este estudio de caudales instantáneos, están distribuidas por la Península Ibérica, cubriendo las tres principales zonas climáticas distinguidas en la España peninsular: el clima mediterráneo, que se caracteriza por veranos secos y cálidos, e inviernos

templados y húmedos; el clima oceánico, que se encuentra en la parte norte del país; y el clima semiárido, que está presente en el centro y el sureste del país, donde, en contraste con el clima mediterráneo, la estación seca continúa más allá del final del verano.

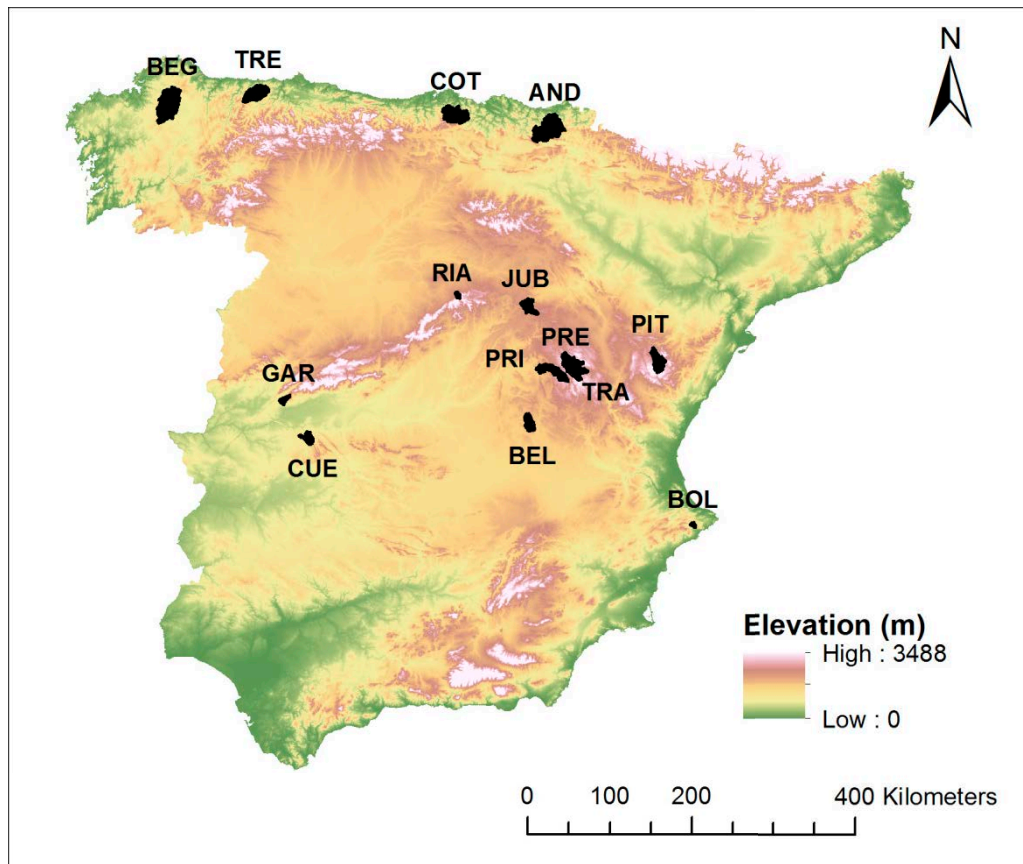


Figura 3. Localización de las 14 cuencas para el estudio de estimación de caudales instantáneos.

La Tabla 2 enumera las 14 cuencas con áreas comprendidas entre 29 y 837 km², altitudes medias desde 16 a 1278 m s.n.m. y con longitudes de registros de caudales disponibles de 38 a 70 años. De acuerdo con el sistema de clasificación climática de Köppen (Kottek, Grieser, Beck, Rudolf, & Rubel, 2006), entre las 14 cuencas, seis de ellas son consideradas climas mediterráneos con veranos suaves (Csb), cuatro de ellas se consideran climas oceánicos (Cfb), tres son consideradas climas mediterráneos con veranos secos y calurosos (Csa), y una de ellas representa el clima semiárido (Bsk).

Tabla 2. Resumen de las principales características de las 14 cuencas seleccionadas para el estudio de estimación de caudales instantáneos.

Nombre estación de aforo	Código	Área (km²)	Altitud (m)	Índice R-B	Clasificación Köppen	Datos disponibles (años)
Trevías	TRE	411	35	0.24	Cfb	43
Begonte	BEG	843	395	0.24	Csb	43
Coterillo	COT	485	16	0.47	Cfb	40
Andoain	AND	765	38	0.39	Cfb	43
Priego	PRI	345	818	0.12	Csb	46
Bolulla	BOL	30	120	0.17	Bsk	38
Gargüera	GAR	97	380	0.29	Csa	40
Cuernacabras	CUE	120	305	0.31	Csa	40
Jubera	JUB	196	892	0.10	Csb	62
Tramacastilla	TRA	95	1278	0.10	Csb	48
Belmontejo	BEL	187	830	0.08	Csa	42
Peralejo de las Truchas	PER	410	1143	0.16	Csb	68
Riaza	RIA	36	1139	0.16	Csb	70
Pitarque	PIT	279	990	0.09	Cfb	45

No se ha seleccionado para el estudio ninguna cuenca en el suroeste debido a la falta de datos en esta zona, disponiendo de registros con menos de 10 años en la mayoría de estaciones de aforo. Además, de acuerdo con Senent-Aparicio, Perez-Sanchez, & Bielsa-Artero (2016), el sur de España es una de las regiones con mayor estrés hídrico de Europa, y por ello es muy difícil encontrar cuencas en régimen natural en este área.

Para evaluar la torrencialidad de las cuencas seleccionadas, el índice de Richard-Baker (R-B) (Baker, Richards, Loftus, & Kramer, 2004) fue obtenido. Este índice refleja la velocidad y frecuencia de los cambios a corto plazo en el caudal en respuesta a los eventos de tormentas.

3.2 MODELO SWAT

SWAT (Arnold et al., 1998) es un modelo de simulación continua, semi-distribuido, y físicamente basado, que opera a escala diaria. Fue desarrollado por el Dr. Jeff Arnold en el Departamento de Agricultura de los Estados Unidos con la

Universidad de Texas. SWAT fue principalmente creado para predecir el impacto de las prácticas humanas sobre los recursos hídricos y sobre los sedimentos en cuencas grandes y complejas, con variedad de tipos de suelos, diferentes usos del suelo y condiciones de explotación a lo largo del tiempo. Es un modelo matemático, el cual consiste en la representación de un sistema idealizado con propiedades estructurales importantes de un sistema real, a través de ecuaciones que expresan el funcionamiento de los procesos y las relaciones entre las variables y los parámetros.

Para la simulación de procesos hidrológicos, SWAT divide la cuenca hidrográfica en subcuencas basándose en la red de drenaje y en la topografía. SWAT considera la heterogeneidad espacial de una cuenca dividiendo las subcuencas en múltiples unidades de respuesta hidrológica (HRUs). Las HRUs consisten en zonas homogéneas con el mismo tipo de suelo, uso del suelo y pendiente. El modelo SWAT se materializa en ArcGIS o QGIS integrando diversos datos geoespaciales para representar con precisión las características de la cuenca. SWAT necesita un modelo de elevación del terreno, un mapa de usos del suelo, datos sobre el tipo de suelo y datos climáticos de la zona de estudio. Y se utilizan estos datos como entradas para el análisis de la simulación hidrológica de la escorrentía superficial y recarga de aguas subterráneas.

La simulación de la hidrología de la cuenca en SWAT es separada en dos fases. La primera fase es la fase terrestre del ciclo hidrológico (Figura 4). La fase terrestre determina la cantidad de agua, la carga de sedimentos, nutrientes y pesticidas incorporados al cauce principal de cada subcuenca. La segunda fase es la fase del agua del ciclo hidrológico que queda definida por el encauzamiento y movimiento del agua, de los sedimentos y de los demás componentes determinados en la primera fase a través de la red de cauces de la cuenca hacia el punto de salida. Además de realizar un seguimiento del flujo en el canal, SWAT modela la transformación de las sustancias químicas en la corriente y en el lecho del cauce.

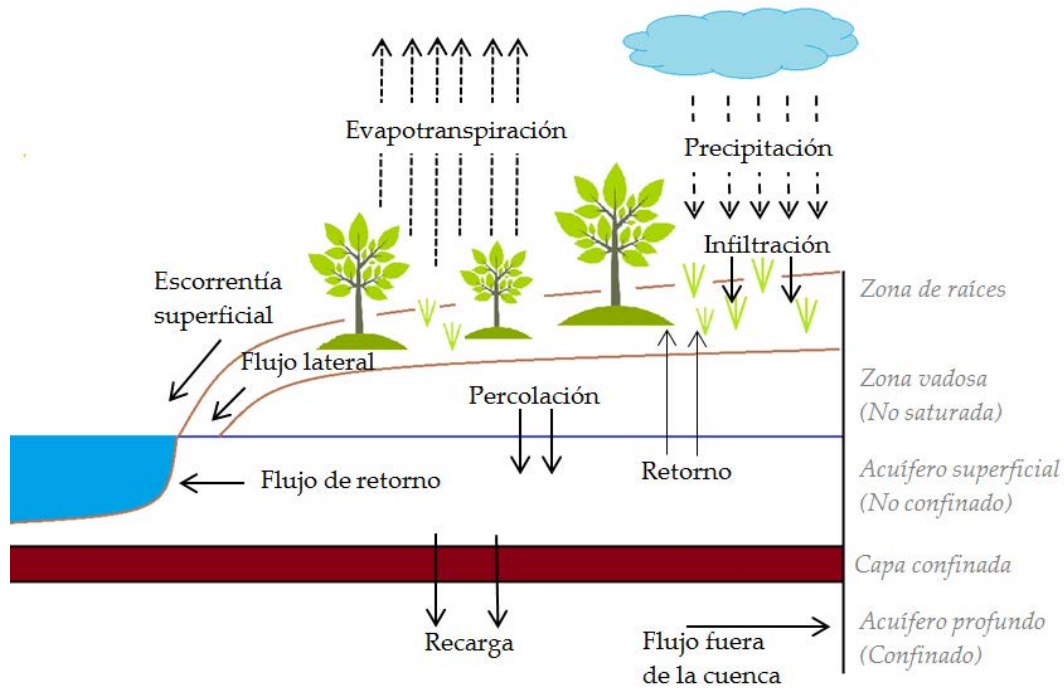


Figura 4. Esquema de la fase terrestre del ciclo hidrológico en SWAT. Fuente: Adaptación propia de SWAT User's Manual (2000).

SWAT simula el ciclo hidrológico basándose en el balance hídrico y este está controlado por el clima (Abbaspour et al., 2015). La ecuación de balance hídrico que rige los componentes hidrológicos del modelo SWAT es la siguiente (Neitsch, Arnold, Kiniry, & Williams, 2011):

$$SW_t = SW_0 + \sum_{i=1}^t (R_{\text{day}} - Q_{\text{surf}} - E_a - W_{\text{seep}} - Q_{\text{gw}}) \quad (1)$$

donde, SW_t es cantidad final de agua en el suelo (mm), SW_0 es la cantidad inicial de agua en el suelo en el día i (mm), R_{day} es la precipitación caída el día i (mm), Q_{surf} es la cantidad de escorrentía superficial en el día i (mm), E_a es la evapotranspiración ocurrida el día i (mm), W_{seep} es la cantidad de agua que percola el día i (mm) y Q_{gw} es el flujo de retorno el día i (mm).

El clima de una cuenca proporciona los aportes de humedad y energía que controlan el balance hídrico y que determinan la importancia relativa de los diferentes componentes del ciclo hidrológico. Las variables climáticas requeridas por SWAT son la precipitación diaria, la temperatura máxima y mínima del aire,

la radiación solar, la velocidad del viento y la humedad relativa. Estas variables pueden ser introducidas como datos observados o pueden ser generados durante la simulación.

El modelo SWAT asume para la modelización del agua en el cauce que el agua circula por canales trapezoidales y en régimen de lámina libre. Aplica la ecuación de Manning para calcular la velocidad de flujo. El agua circula por la red de canales utilizando el método de enrutamiento de almacenamiento variable o el método de Muskingum. Con este procedimiento se van agregando los flujos drenados en cada HRU hasta el punto de salida.

3.2.1 Componentes del modelo SWAT

La precipitación a medida que desciende puede ser interceptada por la vegetación o caer a la superficie terrestre. Una vez en la superficie, el agua se infiltra en el suelo, o bien, fluye por la superficie como escorrentía. La escorrentía fluye relativamente rápido hasta el canal o río, contribuyendo al caudal del río a corto plazo. El agua infiltrada puede quedar retenida en el suelo y después evapotranspirarse, puede moverse lateralmente en el perfil del suelo hasta llegar al cauce, o llegar lentamente y a largo plazo al sistema superficial a través de caminos subterráneos. Una última opción es que el agua percole y se convierta en recarga del acuífero. En esta sección se describen brevemente los diferentes procesos involucrados en la fase terrestre del ciclo hidrológico recogido en la Figura 4.

3.2.1.1 Escorrentía superficial

La escorrentía superficial se produce cuando la precipitación que alcanza la superficie del suelo excede su capacidad de infiltración. A medida que aumenta la humedad en el suelo, dicha infiltración va disminuyendo. SWAT calcula el volumen de escorrentía superficial mediante dos procedimientos: el método del número de curva del Servicio de Conservación de Suelos de Estados Unidos (SCS) (USDA-SCS, 1972) y el método de infiltración de Green & Ampt (1911). En la presente tesis se utiliza como procedimiento para estimar la escorrentía superficial, el método del número de curva.

En el método del número de curva, el efecto de la intercepción también es considerado, y también otros efectos como el almacenamiento superficial del suelo y la infiltración previa a la escorrentía. El número de curva varía de forma no lineal con el contenido de humedad en el suelo y disminuye conforme el suelo se acerca al punto de marchitez, valores cercanos a 0 representan condiciones de permeabilidad muy alta, y aumenta hasta 100 a medida que el suelo se aproxima a la saturación, es decir, a condiciones de impermeabilidad.

Además, en el cálculo de la escorrentía, SWAT considera el desfase que se produce en la escorrentía superficial cuando el tiempo de concentración (tiempo desde que empieza a llover hasta que el caudal de salida se estabiliza) es superior a un día, y así, solo una parte de la escorrentía llega al canal principal el día que es generada.

3.2.1.2 Infiltración

La infiltración es la cantidad de agua que entra en el perfil del suelo desde la superficie. A medida que la infiltración se va produciendo, el suelo se vuelve cada vez más húmedo, lo que hace que la tasa de infiltración disminuya con el tiempo hasta que alcanza un valor estable. Debido a que el método de número de curva utilizado para calcular la escorrentía superficial opera en un paso de tiempo diario, no puede modelar la infiltración directamente. Por lo que la cantidad de agua que ingresa al perfil del suelo se calcula como la diferencia entre la cantidad de lluvia y la cantidad de escorrentía superficial.

3.2.1.3 Evapotranspiración

La evapotranspiración es un término que engloba todos los procesos por los cuales el agua líquida o sólida presente en la superficie terrestre o próxima a ella se convierte en vapor. La evapotranspiración, por lo tanto, incluye la evaporación en ríos y lagos, en la superficie del suelo o de las plantas, la evaporación desde dentro de las plantas (transpiración) y la sublimación del hielo y la nieve.

El modelo SWAT ofrece tres métodos para estimar la evapotranspiración potencial: Penman-Monteith (Monteith, 1965), Hargreaves (Hargreaves, Hargreaves, & Riley, 1985) y Priestley-Taylor (Priestley & Taylor, 1972).

Para el cálculo de la evapotranspiración potencial por Penman-Monteith son requeridos los datos de la radiación solar, la temperatura del aire, la humedad relativa y la velocidad del viento; para Priestley-Taylor son necesarios los datos de la radiación solar, la temperatura del aire y la humedad relativa; mientras que para Hargreaves sólo es requerida la temperatura del aire (temperatura máxima y mínima). En la presente investigación el método escogido para el cálculo de la evapotranspiración es de Hargreaves.

3.2.1.4 Flujo lateral

El flujo subsuperficial lateral, o interflujo, es la contribución al caudal que se origina debajo de la superficie pero sobre la zona saturada, entre los 0 y 2 m de profundidad. Para estimar este flujo subsuperficial, SWAT incorpora un modelo de almacenamiento cinemático desarrollado por Sloan, Morre, Coltharp, & Eigel (1983). Este modelo tiene en cuenta la variación en la conductividad, en la pendiente y en el contenido de agua en el suelo.

3.2.1.5 Percolación

La percolación es calculada para cada capa del perfil del suelo. Cuando el contenido de agua del suelo excede a la capacidad de campo del suelo de una capa, entonces el agua se filtra a la siguiente capa. Cuando la capa de suelo está congelada, SWAT no calcula el flujo de agua de la capa.

3.2.1.6 Flujo de retorno y recarga al acuífero

El flujo de retorno, o flujo base, es el volumen de caudal que procede de aguas subterráneas. El agua que entra en el perfil del suelo por percolación o infiltración, se filtra a través de la zona vadosa antes de convertirse en recarga superficial del acuífero. El modelo SWAT divide las aguas subterráneas en dos sistemas acuíferos. Un acuífero poco profundo no confinado que contribuye con el flujo de retorno a las corrientes dentro de la cuenca, y un acuífero profundo y confinado que contribuye al flujo de retorno a las corrientes fuera de la cuenca (Arnold, Allen, & Bernhardt, 1993). Además del flujo de retorno, el agua almacenada en el acuífero poco profundo puede reponer la humedad en el perfil del suelo en condiciones muy secas o ser eliminada directamente por la planta.

3.2.2 Análisis de sensibilidad, calibración y validación del modelo SWAT

El procedimiento de calibración de SWAT implica un análisis de sensibilidad seguido por una calibración y una validación. El análisis de sensibilidad determina cuanto afectan los cambios en los parámetros del modelo a las salidas del modelo. Es un proceso necesario para identificar los parámetros clave necesarios para la calibración (Ma et al., 2000), y seleccionar aquellos parámetros que tienen un impacto significativo sobre los resultados del modelo. La calibración del modelo es el proceso para estimar el valor de los parámetros mediante la comparación de las salidas de la simulación del modelo con los datos observados para las mismas condiciones. Y por último, el proceso de validación consiste en ejecutar el modelo utilizando los parámetros determinados en la calibración para demostrar que el modelo es suficientemente preciso para el caso de estudio (Moriassi et al., 2007).

La calibración de un modelo puede hacerse de forma manual o automática. La calibración manual se basa en un proceso de prueba y error, implica un ajuste manual de los parámetros del modelo según el criterio del investigador, y posee un gran valor de aprendizaje. Sin embargo, cuando el número de parámetros es grande, la calibración manual se convierte en una tarea lenta y compleja. La calibración automática optimiza los valores de los parámetros utilizando métodos numéricos. Esta calibración implica el cálculo del error de predicción utilizando una ecuación llamada función objetivo, y un procedimiento de optimización automática mediante un algoritmo de búsqueda. Este algoritmo busca los valores de los parámetros que optimizan el valor de la función objetivo (Gupta, Sorooshian, & Yapo, 1999).

En el caso del modelo SWAT, con un gran número de parámetros y de complejo funcionamiento, es más interesante optar por la calibración automática. En la presente tesis se ha empleado para esta tarea, el software SWAT-CUP (SWAT – Calibration Uncertainty Procedures). SWAT-CUP es un programa independiente desarrollado para la calibración de SWAT. El programa ofrece cinco métodos de calibración diferentes, e incluye funcionalidades para validación y análisis de sensibilidad. Los cinco algoritmos incluidos en SWAT-CUP son: GLUE (Beven & Binley, 1992), ParaSol (Van Griensven & Meixner, 2006), MCMC (Markov Chain Monte Carlo) (Kuczera & Parent, 1998), PSO

(Particle swarm optimization) (Eberhart & Kennedy, 1995) y SUFI-2 (The Sequential Uncertainty Fitting version 2) (Abbaspour, Johnson, & Van Genuchten, 2004, Abbaspour et al., 2007). Como algoritmo de calibración se seleccionó para esta investigación el algoritmo SUFI-2, el cual en comparación con las otras opciones de calibración requiere un menor número de simulaciones para lograr el mismo nivel de rendimiento. Además, para los modelos a gran escala que consumen mucho tiempo, se encontró que SUFI-2 era bastante eficiente (Yang & Chang, 2008).

El proceso de calibración con SUFI-2 para el ajuste de los valores de los parámetros seleccionados incluye los siguientes pasos:

1. Definición de la función objetivo
2. Definición del rango inicial de los parámetros que se quieren optimizar.
3. Realización de un análisis de sensibilidad de los parámetros.
4. Ejecución de N simulaciones, guardando las variables de salida obtenidas.
5. Cálculo de la función objetivo para evaluar las simulaciones.
6. Definición del nuevo rango de parámetros y repetición de las simulaciones hasta conseguir el ajuste deseado.

El análisis de sensibilidad se lleva a cabo manteniendo todos los parámetros constantes a valores realistas, mientras se varía cada parámetro dentro del rango asignado en el paso dos. Para cada parámetro, se realizan alrededor de cinco simulaciones simplemente dividiendo los rangos absolutos en intervalos iguales y permitiendo que el punto medio de cada intervalo represente ese intervalo. SUFI-2 realiza un análisis de regresión múltiple calculando los valores estadísticos del *t-stat* y *p-value*. El *p-value* de cada término comprueba la hipótesis de si la media de las muestras está cercana a la esperada. Valores pequeños de *p-value* (< 0.05) indican que el parámetro es significativo en el cálculo de la función objetivo. Valores altos de *p-value* significan que el parámetro es poco influyente.

Los resultados de las simulaciones dependen del estado del sistema en el tiempo cero, por lo que debe tenerse especial atención al escoger estas condiciones. Para ello se utiliza el periodo de calentamiento, el cual consiste en un

periodo inicial (2-5 años) para que el modelo se estabilice y se ajuste de forma correcta a la realidad y así mejorar la calidad de la simulación.

Finalmente, el proceso de validación consiste en ejecutar el modelo con los valores de los parámetros obtenidos en la calibración. Para la validación se utilizan datos de entrada, en este caso datos climatológicos, de periodos distintos a los empleados en la calibración. Su objetivo es probar el modelo en otros periodos de tiempo a los calibrados, dándole robustez al modelo y garantizando que puede usarse bajo cualquier escenario.

3.3 MODELO STM Y CORRECCIÓN DEL *UNDER-CATCH*

El modelo STM (Snow-Témez Model) es un nuevo modelo de balance hidrológico desarrollado en la presente tesis mediante el acoplamiento de un modelo de nieve distribuido basado en el modelo TIM (Temperature Index Model) al modelo agregado de lluvia-escorrentía de Témez. Este acoplamiento es necesario porque el modelo de Témez no considera los procesos nivales. El modelo de nieve conceptual distribuido acoplado al modelo de Témez se basa en el modelo de nieve descrito por Irannezhad et al. (2015) y considera de forma distribuida los procesos hidrológicos relacionados con la nieve. A continuación se describen ambos modelos acoplados.

3.3.1 Modelo de Témez

El modelo de Témez (1977) es un modelo de pocos parámetros, siendo esto una gran ventaja en cuencas en las que se disponen de pocos datos. Las aplicaciones prácticas de este modelo es la obtención de serie de caudales a partir de series de precipitación y temperatura, y la extensión de series históricas de caudales a partir de series más largas de precipitación y temperatura.

Este modelo matemático en conjunto no es un modelo lineal, aunque sí lo es alguno de sus subsistemas. Realiza un balance de humedad entre los distintos procesos de transporte de agua que se dan en un sistema hidrológico durante las diferentes fases del ciclo hidrológico. Sigue el principio de continuidad o conservación de la masa y está regulado por leyes específicas de reparto y transferencia entre los distintos términos del balance. La escala temporal a

emplear puede ser la que se necesite, siempre que el periodo no sea excesivamente corto, para permitir que el balance del agua se equilibre entre las distintas etapas del ciclo hidrológico (Témez, 1977). El balance de humedad está constituido por el flujo entrante de precipitación, el cual se reparte entre una serie de flujos intermedios (Infiltración) y almacenamientos intermedios (Humedad del suelo y volumen almacenado en el acuífero), y unos flujos salientes (Evapotranspiración real, caudal superficial y subterráneo) (Paredes et al., 2014). En la Figura 5 se presenta un esquema conceptual del modelo de Témez.

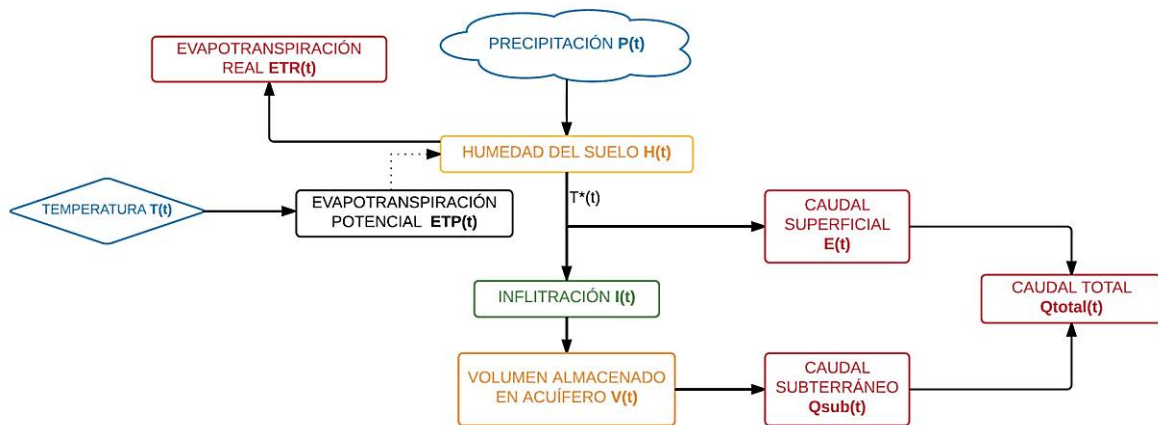


Figura 5. Esquema del ciclo hidrológico del modelo de Témez

El modelo presenta de forma simplificada los diferentes procesos del ciclo hidrológico, siendo estos mucho más complejos en la realidad. La formulación de los diferentes subprocesos que se integran en el modelo queda recogida en las siguientes ecuaciones (Témez, 1977):

1. Cálculo del excedente de lluvia $T^*(t)$:

$$\begin{cases} T^*(t) = 0 & \text{si } P(t) \leq P_0 \\ T^*(t) = \frac{(P(t) - P_0)^2}{P(t) + \delta - 2 \cdot P_0} & \text{si } P(t) > P_0 \end{cases} \quad (2)$$

$$\delta(t) = H_{max} - H(t - 1) + ETP(t) \quad (3)$$

$$P_0(t) = C(H_{max} - H(t - 1)) \quad (4)$$

2. Actualización del estado de la humedad en el suelo $H(t)$:

$$H(t) = \max(0; H(t-1) + P(t) - T^*(t) - ETP(t)) \quad (5)$$

3. Cálculo de la infiltración subterránea $I(t)$ y de la escorrentía superficial $E(t)$:

$$I(t) = I_{max} \frac{T^*(t)}{T^*(t) + I_{max}} \quad (6)$$

$$E(t) = S(T^*(t) - I(t)) \quad (7)$$

4. Cálculo del volumen almacenado en el acuífero $V(t)$ y del caudal subterráneo drenado $Q_{sub}(t)$:

$$V(t) = V(t-1) \cdot \exp^{-\alpha \Delta t} + \frac{S \cdot I(t)}{\alpha} (1 - \exp^{-\alpha \Delta t}) \quad (8)$$

$$Q_{sub}(t) = V(t-1) - V(t) + I(t) \cdot S \quad (9)$$

5. Cálculo del caudal total $Q_{total}(t)$:

$$Q_{total}(t) = E(t) + Q_{sub}(t) \quad (10)$$

Los datos (inputs) necesarios para el modelo son tres, precipitación en el instante t ($P(t)$), la temperatura media para el instante t ($T(t)$) y la superficie de la cuenca (S). Las variables de cálculo son la capacidad disponible en cada instante t para el almacenamiento del agua en el suelo ($\delta(t)$) y el umbral de inicio de la escorrentía en el instante t ($P_0(t)$). Las variables de estado a inicializar son la humedad inicial del suelo en el instante $t = 0$ (H_0) y el volumen inicial del acuífero en el instante $t = 0$ (V_0), y su valor es obtenido a través de la calibración. Los parámetros que el modelo requiere calibrar son cuatro: H_{max} y C que regulan el almacenamiento de agua en el suelo, H_{max} es la máxima capacidad de humedad en el suelo, y C es un coeficiente de inicio de excedente; I_{max} es la infiltración máxima al acuífero, y regula la parte de agua que se infiltra al acuífero y la que

sale del sistema superficialmente; α regula la cantidad de agua que drena desde el acuífero hacia el exterior del sistema.

El excedente de lluvia $T^*(t)$ es la parte del agua de lluvia $P(t)$ que acaba siendo drenada y sale al exterior, a través del cauce del río. El resto de precipitación ($P(t) - T^*(t)$) se almacena en el suelo en forma de humedad $H(t)$ para alimentar a la evapotranspiración $ETR(t)$ en tiempos posteriores. Siendo la evapotranspiración el conjunto de fenómenos naturales por los que el agua retorna a la atmósfera en estado gaseoso. Este excedente $T^*(t)$ se descompone a su vez en escorrentía superficial $E(t)$ y en infiltración $I(t)$. La escorrentía o caudal superficial $E(t)$, corresponde al agua de lluvia que discurre por la superficie del terreno hacia zonas topográficamente más bajas debido a la acción de la gravedad. La infiltración $I(t)$ corresponde con el agua que se infiltra al acuífero a través de la superficie del terreno. Parte del agua infiltrada desaguará a los cauces dentro de ese mismo intervalo de tiempo, mientras que el resto permanecerá almacenado en el acuífero para salir en fechas posteriores. El caudal subterráneo $Q_{sub}(t)$ es función de la cantidad de agua almacenada en el acuífero $V(t)$ que queda por encima de un umbral de salida al cauce y es igual a la suma de las reservas iniciales del acuífero menos las reservas finales, más la infiltración en ese periodo. Por último, el caudal total $Q_{total}(t)$ que desagua al cauce durante un intervalo de tiempo es la suma del caudal superficial $E(t)$ más el caudal subterráneo $Q_{sub}(t)$, obteniendo así la salida del modelo de Témez. Sobre la evapotranspiración, hay que diferenciar entre la evapotranspiración real ($ETR(t)$), que es un output del modelo, y la evapotranspiración potencial ($ETP(t)$), que es una variable de cálculo. Para el cálculo de la ETP se emplea el método de Hargreaves utilizando datos de temperatura y radiación solar.

Todo lo comentado hasta ahora en el modelo de Témez, es utilizado para el modelado puramente pluvial. Para el caso de cuencas alpinas con procesos nivales, este modelo no podría ser aplicado como tal, puesto que la limitación de este modelo es que no simula los fenómenos que reproducen los procesos de nieve. Por ello, es necesario agregar a este modelo un modelo de nieve que reproduzca las aportaciones de caudales a la cuenca como consecuencia del deshielo. El flujo resultante del modelo de nieve, que es el que corresponde a la lluvia líquida más el flujo de la fusión de la nieve, constituye la entrada al modelo de Témez, para así obtener las salidas del sistema que son la evapotranspiración

real y el caudal. La calibración del modelo se realiza con las series observadas de caudales restituidas a régimen natural.

3.3.2 Modelo de Nieve

El modelo de nieve empleado en este trabajo es el llamado TIM (The temperature-index snowmelt model) (Hock, 2003; Irannezhad et al., 2015). En él se asume un factor llamado grado-día que relaciona la temperatura del aire con la fusión de la nieve. El modelo TIM es el más empleado para el modelado de la fusión, debido a tres razones (Hock, 2003): (i) La amplia disponibilidad de datos de temperatura del aire o la facilidad de obtener los datos de temperatura por predicción o interpolación; (ii) el buen rendimiento del modelo a pesar de su simplicidad; (iii) el modelo es computacionalmente simple.

La formulación del modelo TIM se expone a continuación (Adaptación de Irannezhad et al. (2015)):

1. Cálculo de la fracción de precipitación que corresponde con agua líquida ($P_r(t)$) y la fracción que es precipitación sólida ($P_s(t)$):

$$P_r(t) = P(t) \cdot F_r(t) \cdot C_r \quad (11)$$

$$P_s(t) = P(t) \cdot F_s(t) \cdot C_s \quad (12)$$

$$F_r(t) = \begin{cases} 0 & T(t) \leq T_{min} \\ \frac{T(t) - T_{min}}{T_{max} - T_{min}} & T_{min} < T(t) \leq T_{max} \\ 1 & T(t) > T_{max} \end{cases} \quad (13)$$

$$F_s(t) = 1 - F_r(t) \quad (14)$$

2. Cálculo de la cantidad de agua procedente de la fusión de la nieve ($SM(t)$):

$$SM(t) = \min \begin{cases} 0 & T(t) \leq T_{melt} \\ K_d(T(t) - T_{melt}) & T(t) > T_{melt} \\ SI2(t - 1) \end{cases} \quad (15)$$

3. Cálculo de la cantidad de agua que tras fundirse vuelve a congelarse (SF(t)):

$$SF(t) = \min \begin{cases} 0 & T(t) \geq T_f \\ K_f(T_f - T(t))^a & T(t) < T_f \\ SL2(t-1) & \end{cases} \quad (16)$$

4. Cálculo de la cantidad de agua en estado sólido en el paquete de nieve (SI(t)):

$$SI(t) = SI2(t-1) + P_s(t) + SF(t) - SM(t) \quad (17)$$

5. Cálculo de la cantidad de agua líquida retenida en el paquete de nieve (SL(t)):

$$SL(t) = \min \begin{cases} Ret \cdot SI(t) \\ SL2(t-1) + P_r(t) + SM(t) - SF(t) \end{cases} \quad (18)$$

6. Cálculo de la evaposublimación (ES(t)) (Herrero & Polo, 2016):

$$S(t) = \min \begin{cases} k_{ES} \cdot SM(t) / (1 - k_{ES}) \\ SI(t) + SL(t) \end{cases} \quad (19)$$

7. Actualización de estado de SI(t) y SL(t) por pérdidas por evaposublimación en el paquete de nieve, SI2(t) y SL2(t):

$$\begin{cases} si ES(t) \geq SL(t) \\ si ES(t) < SL(t) \end{cases} \begin{cases} SI2(t) = \max \begin{cases} 0 \\ SI(t) - (ES(t) - SL(t)) \end{cases} \\ SL2(t) = 0 \\ SI2(t) = SI(t) \\ SL2(t) = SL(t) - ES(t) \end{cases} \quad (20)$$

8. Cálculo del Snow Water Equivalent (SWE(t)):

$$SWE(t) = SI(t) + SL(t) - ES(t) \quad (21)$$

9. Cálculo del flujo de fusión (ML(t)):

$$ML(t) = \max \left\{ \begin{array}{l} 0 \\ SM(t) - SF(t) - (Ret \cdot SI2(t)) + SL2(t - 1) \end{array} \right. \quad (22)$$

10. Cálculo del flujo de salida del paquete de nieve $Rw(t)$:

$$\left\{ \begin{array}{l} Si \ SWE(t) = 0 \\ Si \ SWE(t) > 0 \end{array} \right. \rightarrow \left\{ \begin{array}{l} Rw(t) = SL2(t - 1) + SM(t) + P_r(t) \\ Si \ ML(t) > 0 \rightarrow Rw(t) = ML(t) + P_r(t) \\ Si \ ML(t) = 0 \rightarrow Rw(t) = \max \left\{ \begin{array}{l} 0 \\ SM(t) - SF(t) - (Ret \cdot SI2(t)) + SL2(t - 1) + P_r(t) \end{array} \right. \end{array} \right. \quad (23)$$

Los datos de entrada al modelo son dos: $P(t)$ precipitación en el instante t y $T(t)$ temperatura en el instante t . Las variables de estado a inicializar son $SI2(t)$ y $SL2(t)$ para el instante inicial $t=0$. Sus valores serán de 0 debido a que la simulación comienza el 1 de octubre y en esa fecha se puede asumir que no existe cobertura de nieve. Los parámetros que el modelo requiere calibrar son once, a continuación se enumeran junto con su rango de valores (Irannezhad et al., 2015):

1. T_{min} : Temperatura umbral mínima en la formación de nieve ($^{\circ}C$) [-6.1 , 2]
2. T_{max} : Temperatura umbral máxima en la formación de nieve ($^{\circ}C$) [2 , 7]
3. C_r : coeficiente de corrección de la medición de lluvia [1 , 1.4]
4. C_s : coeficiente de corrección de la medición de nieve [1 , 1.8]
5. T_{melt} : Temperatura umbral para la fusión de nieve ($^{\circ}C$) [0 , 4]
6. T_r : Temperatura umbral para la recongelación del agua líquida ($^{\circ}C$) [-5,-0.001]
7. K_d : Factor grado-día ($mm/^{\circ}C \cdot día$) [0.1 , 15]
8. K_r : Factor recongelación ($mm/^{\circ}C \cdot día$) [0.02 , 5.1]
9. a : Exponente de la función recongelación [0.001 , 1]
10. Ret : Capacidad de retención de agua líquida del paquete de nieve [0.02 , 0.52]
11. K_{Es} : coeficiente de evaposublimación. Indica que parte de la ablación es evaposublimación [0.1,0.5]

El dato de salida del modelo es $Rw(t)$ en mm, correspondiente al flujo líquido que entra al modelo de precipitación-escorrentía de Témez. El esquema del modelo STM se muestra a continuación donde el subíndice c e i denotan las variables asociadas con la celda c para el tiempo i . La primera parte del modelo relacionado con la nieve funciona de forma distribuida (por celdas) y en la segunda parte funciona de una forma agregada (agregando los resultados de todas las celdas para cada i).

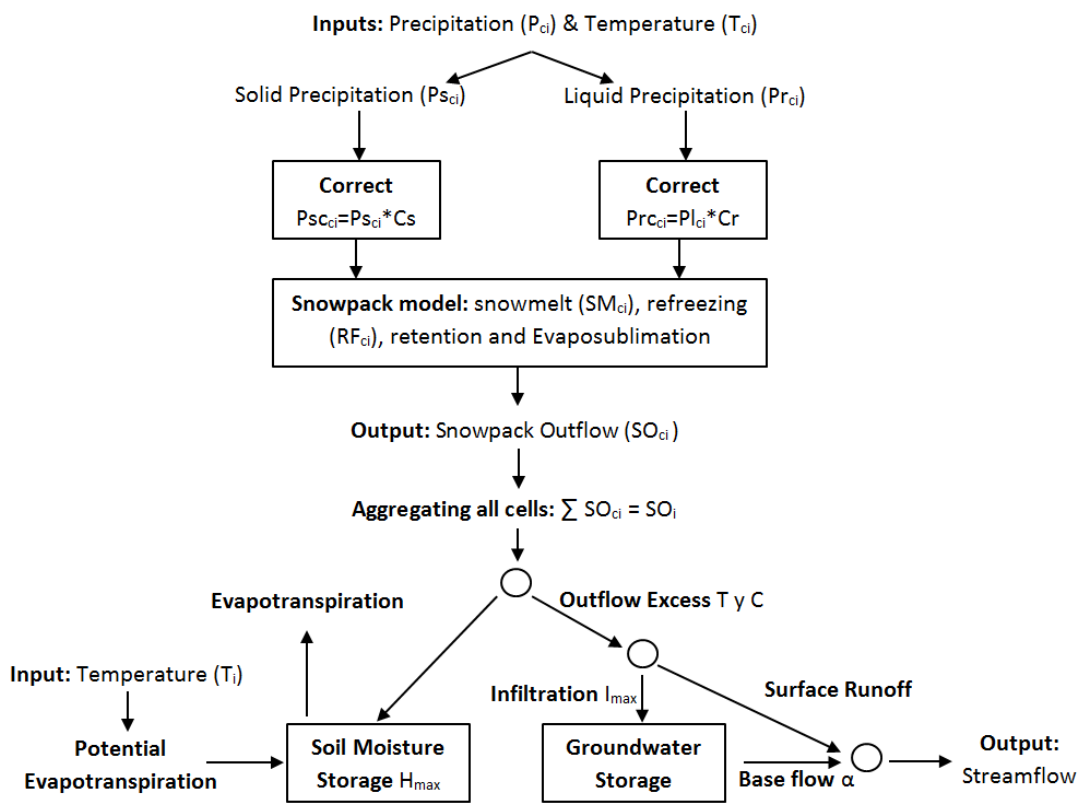


Figura 6. Diagrama del modelo STM (Snow-Témez Model).

3.4 ALGORITMOS DE MACHINE LEARNING

Machine learning o aprendizaje automático es una rama de la inteligencia artificial que busca que los ordenadores sean capaces de aprender e inducir conocimiento a partir de los datos. Un método de machine learning es un algoritmo que estima una dependencia, hasta ese momento desconocida, entre las

entradas a un sistema (inputs) y sus salidas (outputs) a partir de los datos disponibles. A medida que se descubre esa relación de dependencia, esta se puede utilizar para predecir o estimar los resultados del sistema futuro a partir de los valores de entrada conocidos. Cuatro técnicas de machine learning se han utilizado y comparado en esta tesis: RNA, ANFIS, SVM, y ELM. Cada uno de estos métodos podría ser utilizado con una gran variedad de configuraciones. En la presente tesis se han escogido las configuraciones clásicas de los algoritmos utilizadas para la mayoría de las aplicaciones existentes. A continuación, se recogen los conceptos básicos de cada una de las técnicas utilizadas. Las redes neuronales artificiales (RNAs) se explican con mayor detalle, debido a que son empleadas en los tres artículos publicados que forman parte de esta tesis.

3.4.1 Red neuronal artificial (RNA)

Una red neuronal artificial es un sistema de procesamiento de información distribuido, donde el aprendizaje está basado en los procesos neuronales que tienen lugar en el cerebro humano (Haykin, 1999). La idea que inspiró su desarrollo fue el deseo de desarrollar un sistema artificial que realizara tareas del mismo modo que un cerebro, adquiriendo conocimientos mediante aprendizaje y almacenando los conocimientos adquiridos. Una RNA aprende, memoriza y divulga las diversas relaciones encontradas en los datos. Es capaz de modelar complejas relaciones no lineales encontradas en los datos de una cuenca hidrográfica sin un conocimiento previo y explícito de las características físicas del proceso (Shiau & Hsu, 2016; Singh et al., 2012).

Una RNA consiste en un agrupamiento de neuronas artificiales ordenadas en capas y conectadas entre sí. Cada neurona consta de conexiones de entrada y de salida, y en su núcleo se procesa y agrega la información que recibe mediante las entradas (inputs). La forma en la que las neuronas están conectadas define la arquitectura de la red, existiendo numerosas arquitecturas diferentes de redes. Las redes pueden ser de una sola capa, o multicapa de acuerdo con el número de capas; y redes feed-forward, recurrentes o autoorganizadas según la dirección del flujo de la información y de su procesamiento. En la presente tesis se han utilizado las redes feed-forward multicapa, o también llamadas redes perceptrón multicapa, las cuales son las más populares en hidrología (Maier, Jain, Dandy, &

Sudheer, 2010) y las más ampliamente utilizadas para simular procesos hidrológicos (p. ej., Amirhossien et al., 2015; Gholami, Chau, Fadaee, Torkaman, & Ghaffari, 2015; Olyaie et al., 2015; Shiau & Hsu, 2016).

En la red perceptrón multicapa (MLP, por sus siglas en inglés), las neuronas están dispuestas de forma paralela en capas secuenciales, comenzando en una primera capa de entrada y terminando en una capa de salida. Entre estas dos capas puede haber una o más capas ocultas, y cada capa puede estar formada por una o más neuronas. Las neuronas están conectadas con todas las neuronas de la siguiente capa inmediata mediante conexiones sinápticas ponderadas, y no hay conexión entre las neuronas de la misma capa. Las redes MLP son redes feed-forward porque son redes alimentadas hacia adelante, es decir, la información pasa desde la entrada hacia la salida.

La capa de entrada es el medio para proporcionar la información (inputs) a la red; las neuronas de esta capa reciben señales (inputs) del exterior y producen una señal saliente, que se convierte en la señal entrante para la capa siguiente del sistema. Las capas ocultas procesan la información. El proceso continúa hasta que la capa de salida emite una o más señales (outputs) hacia el exterior, devolviendo los valores procesados por la red que representan las salidas del modelo. Esta estructura de la red se puede ver en la Figura 7.




Figura 7. Arquitectura de la red perceptrón multicapa, donde: n es el número de variables de entrada a la red; L es el número total de capas ocultas; y k es el número de variables de salida de la red.

De forma resumida, el esquema de funcionamiento de estas RNAs es el siguiente (ASCE, 2000a): (i) La información se procesa en las neuronas, cada neurona recibe una matriz de entradas o señales; (ii) estas señales pasan entre las neuronas a través de enlaces de conexión; (iii) cada neurona forma una combinación lineal de las señales de entrada de acuerdo con sus pesos, y a continuación realiza una transformación, normalmente no lineal, a través de una función de activación o de transferencia para producir una señal de salida.

La capacidad de aprendizaje de una red queda determinada por su arquitectura y por el algoritmo utilizado en su entrenamiento. La determinación del número de capas ocultas y de neuronas en cada una de ellas, puede considerarse como una tarea de optimización, que se realiza por un procedimiento de prueba y error.

3.4.1.1 Modelo matemático de la red MLP

Antes de describir el funcionamiento matemático de una RNA, se definen con mayor detalle los diferentes elementos y conceptos que constituyen una red:

- **Neuronas:** son unidades elementales que reciben las señales del exterior o las señales de salida de otras neuronas vecinas a través de conexiones o sinapsis. Tras procesar estas señales, envían la señal a otras neuronas o al medio externo. En función de la capa en la que se encuentren las neuronas, estas pueden ser de los siguientes tipos: (i) Las neuronas de entrada son las situadas en la capa de entrada, recibiendo las señales de entrada desde el exterior, es decir, lo que matemáticamente corresponden a los valores de las variables independientes de la función que se va a representar con la RNA; (ii) las neuronas ocultas son las situadas en las capas ocultas y las señales de entrada y salida a estas neuronas permanecen dentro de la red; (iii) y las neuronas de salida son las situadas en la capa de salida y sus señales de salida se emiten hacia el exterior de la red, es decir, equivalen a los valores de las variables dependientes de la función a representar.
- **Estado de activación, campo local inducido o entrada neta:** es un valor que representa el nivel de activación de la neurona y corresponde matemáticamente a la agregación ponderada de las señales individuales que recibe una neurona de otras neuronas. Se diferencian dos estados de

activación: (i) estado de activación positivo, si la neurona es activa; (ii) y estado de activación negativo, si la neurona es pasiva.

- **Funciones de activación o de transferencia:** son funciones que transforman el estado actual de activación de una neurona en una señal de salida.
- **Conexiones sinápticas:** son los enlaces entre las neuronas a través de los cuales se transmite la información de unas neuronas a otras. A cada conexión le corresponde un peso sináptico, cuya magnitud representa la intensidad o fuerza de la conexión. Dichos pesos almacenan el conocimiento de la red, es decir, parametrizan las relaciones matemáticas entre las variables de la red; si la contribución del peso es positiva se considera que es una conexión excitatoria, y si es negativa se considera como una inhibición, mientras que los pesos nulos hacen que la conexión se considere inexistente.
- **Umbral de activación, sesgo o bias:** es un parámetro asociado a cada neurona que representa el desfase entre la entrada neta y su respectiva función de activación.

El modelo matemático de una neurona constituye la base para el diseño de cualquier red neuronal artificial. El diagrama esquemático típico de una neurona j de una capa l con m inputs se muestra en la Figura 8.

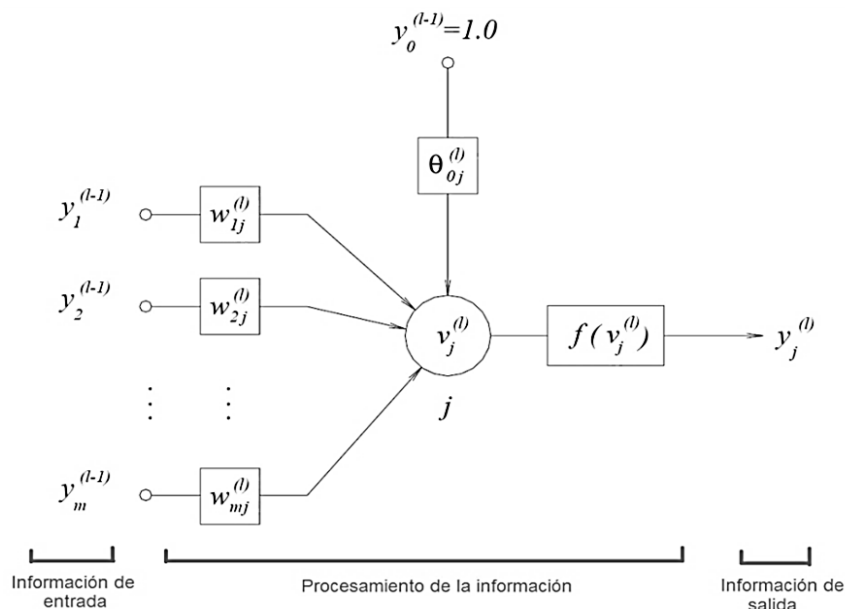


Figura 8. Modelo matemático de una neurona j en una RNA. Fuente: Ochoa-Rivera, García-Bartual, & Andreu (2002).

El vector de entrada a una neurona j está formado por las señales $y_i^{(l-1)}$, estas señales provienen de un sistema de variables causales (variables independientes) o son las salidas de las neuronas de una capa anterior $l-1$. Cada señal de entrada se modula según el peso $w_{ij}^{(l)}$ correspondiente a su conexión con la neurona j , y a continuación son agregadas para formar la entrada neta $v_j^{(l)}$, incorporando el bias $\theta_{0j}^{(l)}$. En términos matemáticos esto se define con la siguiente ecuación (Haykin, 1999):

$$v_j^{(l)} = \sum_{i=1}^{m_{l-1}} w_{ij}^{(l)} \cdot y_i^{(l-1)} + \theta_{0j}^{(l)} \quad (24)$$

El bias $\theta_{0j}^{(l)}$ suele tratarse como un peso más de la red $w_{0j}^{(l)}$, representado por una conexión que conecta una señal de entrada $y_0^{(l-1)}$, ajustada a +1, a la neurona j . Pudiéndose simplificar la ecuación 24 de la siguiente forma (Haykin, 1999):

$$v_j^{(l)} = \sum_{i=0}^{m_{l-1}} w_{ij}^{(l)} \cdot y_i^{(l-1)} \quad (25)$$

Finalmente aplicando la función de activación se transforma la entrada neta $v_j^{(l)}$ (ecuación 24) en una señal de salida $y_j^{(l)}$ (ecuación 26) la cual es transmitida a las neuronas de las capas siguientes o al exterior de la red:

$$y_j^{(l)} = f(v_j^{(l)}) \quad (26)$$

La función de transferencia $f()$ (ecuación 26) calcula la salida de la neurona en función de su entrada. Estas funciones, junto con los pesos, establecen la operación de la red, siendo las funciones de activación las que establecen los límites del rango de los valores de las salidas, lo que hace que estas jueguen un papel esencial en la red. Hay un gran número de funciones de activación. A continuación se exponen los tres tipos de funciones más empleadas:

- **Funciones escalón o funciones umbral:** se emplean para redes con salidas binarias, es decir, dos posibles valores. La señal de salida dependerá de si el estado de activación v es mayor, igual, o menor a un cierto valor umbral. Dos

funciones escalón con umbral igual a cero quedan descritas de la siguiente forma:

$$f(v) = \begin{cases} 1 & v \geq 0 \\ -1 & v < 0 \end{cases}$$

$$f(v) = \begin{cases} 1 & v \geq 0 \\ 0 & v < 0 \end{cases}$$




Figura 9. Funciones de activación tipo escalón o umbral.

- **Funciones mixtas o semi-lineales:** combinan una función lineal y una función escalón. Es muy frecuente la utilización de la función lineal simple $f(v)=v$, especialmente en las neuronas de la capa de salida. A continuación se muestran dos ejemplos de funciones mixtas.




Figura 10. Funciones de activación tipo mixta o semi-lineal.

- **Funciones sigmoideas:** son las más populares en la construcción de redes neuronales debido a que son funciones no lineales que se pueden aproximar a funciones escalón elevando el valor del parámetro de la pendiente, además de que son diferenciables mientras que las funciones escalón no lo son (Haykin, 1999). Dos ejemplos de este tipo son la función logística y la tangente hiperbólica, las cuales se muestran a continuación, donde a es la pendiente.




Figura 11. Función sigmoide logística (izquierda) y función sigmoide tangente hiperbólica (derecha).

No existen reglas para poder considerar a priori la función de activación más idónea para una red, pero si hay ciertos criterios a tener en cuenta para descartar ciertos tipos de funciones. Si las salidas de la red son variables continuas, las funciones escalón se descartan. Las funciones de activación habitualmente empleadas son funciones no lineales, continuas, y limitadas para controlar la amplitud de los valores de los outputs. La función sigmoide logística y la tangente hiperbólica (Figura 11) son las más comúnmente utilizadas en las capas ocultas con un rango de salida de 0 a 1 y de -1 a 1, respectivamente (Makwana & Tiwari, 2017); mientras que en la capa de salida, utilizar una función lineal es lo habitual para que el rango de valores de salida no quede limitado.

3.4.1.2 Proceso de aprendizaje de la red MLP

El entrenamiento de una RNA es un proceso mediante el cual la red va ajustando sus pesos como respuesta a una información de entrada y a otra de salida. Para que la red aprenda las relaciones existentes entre las variables de entrada (variables independientes) y de salida (variables dependientes), éstas deben presentarse de forma reiterada. Cada presentación del conjunto completo de datos de entrada constituye lo que se llama una época (*epoch*). El entrenamiento de la red se realiza hasta la obtención de unas salidas adecuadas. Para ello es necesario ir modificando los valores de los parámetros hasta conseguir que la diferencia entre los valores de salida obtenidos en la red (outputs) y los valores observados (targets) sea la mínima posible. Durante el

aprendizaje los cambios que se producen son la destrucción, modificación o creación de conexiones. La destrucción supone hacer nulo el peso de la conexión, y por el contrario, la creación implica hacerlo distinto de cero. El entrenamiento de la red acaba cuando los valores de los pesos, después de sucesivos cambios que se dan en cada época o de una época a otra, permanecen constantes.

El criterio empleado para la modificación de los pesos es lo que se llama regla de aprendizaje, pudiendo ser éste de dos tipos en función de si existe un supervisor externo o no: (i) En el aprendizaje supervisado los valores de salida deseados (targets) son conocidos. Hay un supervisor que controla el entrenamiento y que va realizando una comprobación de si la salida de la red coincide con el valor deseado, modificando los pesos hasta lograrlo; (ii) en el aprendizaje no supervisado no hay un agente externo que realice el ajuste de los pesos y la red no recibe información externa para la comprobación de la salida.

En el caso de redes MLP, el aprendizaje se realiza con métodos supervisados, donde el valor actual de la salida de la red (output) es comparado con el valor de salida deseado (target), terminando con un error en cada celda de salida. El rendimiento de la red puede medirse con el error cuadrático medio (MSE, por sus siglas en inglés), es decir, el error medio al cuadrado:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (27)$$

donde, e_i es el error calculado como la diferencia entre y_i e \hat{y}_i , siendo \hat{y}_i el valor obtenido en la red (output), e y_i el valor observado o deseado. El objetivo del proceso de aprendizaje de la red consiste en minimizar este error encontrando el mejor valor para cada uno de los pesos y bias. Cuando comienza el entrenamiento, los pesos son establecidos aleatoriamente, y en la iteración siguiente se establecerán unos pesos que aproximen mejor el output actual con el deseado.

Los algoritmos de optimización para minimizar el error de la red utilizan el gradiente o el jacobiano del error de la red con respecto a sus pesos. El gradiente o jacobiano son calculados empleando la técnica de retropropagación (*backpropagation*, en inglés), la cual propaga las señales de error hacia atrás. Los errores de salida son retroalimentados repetidamente a la red para ir ajustando los parámetros de la red (pesos y bias).

3.4.2 Sistemas adaptativos de inferencia neuro-difusa (ANFIS)

Este algoritmo emula un conjunto de datos de entrenamiento dado y descubre patrones ocultos dentro de él (Talebizadeh & Moridnejad, 2011). En este apartado se presentan los conceptos básicos de la arquitectura de la red ANFIS y su regla de aprendizaje híbrida. El modelo ANFIS (*Adaptative Network based in Fuzzy Inference Systems*) se basa en el trabajo de Jang (1993). ANFIS integra la capacidad adaptativa de aprendizaje de las RNAs, y la capacidad de razonamiento del sistema de inferencia difusa (FIS). Un sistema FIS es un marco computacional que combina el concepto de la lógica difusa, las reglas de decisión difusa y el razonamiento difuso (Jang & Sun, 1995), y permite describir el lenguaje y el razonamiento humano en el contexto de las matemáticas (Firat, Turan, & Yurdusev, 2009).

La combinación de RNA y FIS, permite que un sistema de inferencia difusa aprenda de los datos para crear un modelo eficiente para determinar el comportamiento de sistemas dinámicos complejos definidos de forma imprecisa (Kim & Kasabov, 1999). ANFIS modela funciones no lineales y hace un mapa no lineal desde el espacio de entrada al espacio de salida usando reglas difusas tipo *if-then*, con cada regla se describe el comportamiento local del mapeo. Los parámetros de estas reglas determinan la eficacia del sistema FIS y describen la forma de las funciones de pertenencia (MF, por sus siglas en inglés).

El funcionamiento de este modelo se puede resumir en los siguientes pasos: (i) Las características de entrada se asignan o mapean a unas MFs de entrada; (ii) estas MFs están relacionadas con reglas, que a su vez están relacionadas con un conjunto de características de salida; (iii) las características de salida se asignan o mapean a unas MFs de salida; y (iv), finalmente, estas MFs de salida están relacionadas con un único resultado (Jang, Sun, & Mizutani, 1997). Existen dos métodos típicos para formular este mapeo, FIS de tipo Sugeno (Sugeno & Kang, 1988; Takagi & Sugeno, 1985) y FIS de tipo Mamdani (Mamdani & Assilian, 1975).

En esta investigación, se utilizó el FIS de tipo Sugeno porque es más eficiente desde el punto de vista computacional y más compacto, además de generar un menor error de pronóstico, y en consecuencia es más apropiado para la optimización y para las técnicas adaptativas para construir modelos difusos (Jang & Gulley, 1995). El modelo difuso Sugeno es un enfoque para generar reglas

difusas a partir de un conjunto de datos de entrada y salida, teniendo como objetivo identificar a partir de datos de entrada y salida un sistema no lineal conocido. Una regla difusa típica en un modelo Sugeno tiene el siguiente formato:

$$\text{Si } x \text{ es } A \text{ e } y \text{ es } B, \text{ entonces } z = f(x, y) \quad (28)$$

donde A y B son conjuntos difusos en el antecedente, $z = f(x, y)$ es una función en el consecuente. Generalmente, $f(x, y)$ es un polinomio de las variables de entrada x e y , pero puede ser cualquier otra función que pueda apropiadamente describir la salida del sistema dentro de la región difusa especificada por el antecedente de la regla. Cuando $f(x, y)$ es un polinomio de primer orden, tenemos el modelo difuso de Sugeno de primer orden que propuso originalmente Sugeno & Kang (1988) y Takagi & Sugeno (1985) y que contiene las dos siguientes reglas:

$$\begin{aligned} \text{Regla 1: Si } X \text{ es } A_1 \text{ y } Y \text{ es } B_1, \text{ entonces } f_1 &= p_1 \cdot x + q_1 \cdot y + r_1 \\ \text{Regla 2: Si } X \text{ es } A_2 \text{ y } Y \text{ es } B_2, \text{ entonces } f_2 &= p_2 \cdot x + q_2 \cdot y + r_2 \end{aligned} \quad (29)$$

La Figura 12a ilustra gráficamente el mecanismo de razonamiento difuso para obtener una salida f a partir de un vector de entrada dado $[x, y]$. Las intensidades de las conexiones que conectan dos reglas w_1 y w_2 se obtienen generalmente como el producto del grado de pertenencia en la parte de premisa, y la salida f es el promedio ponderado de la salida de cada regla. La estructura difusa de Sugeno en el modelo ANFIS es una red adaptativa que se compone de cinco capas, donde cada nodo dentro de la misma capa realiza funciones del mismo tipo. En la Figura 12b está representada una red adaptativa con un funcionamiento equivalente al sistema FIS de la Figura 12a.




Figura 12. (a) Modelo difuso de Sugeno de primer orden; (b) Arquitectura ANFIS.
Fuente: Jang (1996)

En la red ANFIS de la Figura 12b, se presentan dos entradas x e y . Cada entrada tiene dos etiquetas lingüísticas (conjuntos difusos) A_1 y A_2 para la variable de entrada x , y B_1 y B_2 para y .

En la primera capa, cada nodo es un nodo adaptativo y actúa como una función de pertenencia (MF). Cada nodo de esta capa genera un grado de pertenencia a una etiqueta lingüística:

$$O_i^1 = \mu_{A_i}(x) \quad (30)$$

donde O_i^j denota la salida del i -ésimo nodo en la capa j -ésima; x es el input al nodo i ; y A_i es la etiqueta lingüística asociado con ese nodo. Las MF más comúnmente utilizadas en la literatura son las funciones triangulares, trapezoidales, gaussianas, de campana generalizada y sigmoideas (Nguyen, Prasad, Walker, & Walker, 2003).

En la capa 2, cada nodo calcula la fuerza de conexión de una regla mediante multiplicación:

$$O_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1,2. \quad (31)$$

En la capa 3, el nodo i calcula la relación entre la fuerza de conexión de la regla i -ésima y el total de todas las fuerzas o pesos:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2. \quad (32)$$

En la capa 4, el nodo i calcula la contribución de la regla i -ésima en la salida general de la siguiente forma:

$$O_i^4 = \bar{w}_i \cdot f_i = \bar{w}_i(p_i x + q_i y + r_i), \quad i = 1,2. \quad (33)$$

donde \bar{w}_i es la salida de la capa 3, y $\{p_n, q_n, r_n\}$ son un conjunto de parámetros.

En la capa 5, el único nodo calcula un output final, como el sumatorio de la contribución de cada regla:

$$O_i^5 = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad (34)$$

Para el entrenamiento de los parámetros del modelo, se utiliza un algoritmo de aprendizaje híbrido, que representa una combinación del método de mínimos cuadrados y el método *backpropagation* de descenso del gradiente, y calcula las señales de error recursivamente desde la capa de salida hacia atrás a los nodos de entrada. Esta regla de aprendizaje es la misma que la utilizada en las redes neuronales feed-forward (Jang, 1996).

3.4.3 Máquinas de Vectores de Soporte (SVM)

Las máquinas de soporte vectorial, de vectores soporte o de vector soporte (SVM, del inglés *Support Vector Machines*) son un conjunto de algoritmos de aprendizaje supervisado que tienen su origen en los trabajos sobre la teoría del aprendizaje estadístico e introducidos en los años 90 por Cortes & Vapnik (1995). Originariamente las SVMs fueron ideadas para la resolución de problemas de clasificación, sin embargo, actualmente son también aplicadas para resolver problemas de regresión. En la presente tesis se aborda el problema de regresión

mediante lo que se conoce como SVR (del inglés, *Support Vector Regression machines*).

Dado un conjunto de entrenamiento de N ejemplos $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, donde $x_i \in \mathbb{R}^d$ denota el vector de entrada, e $y_i \in \mathbb{R}$ es su salida correspondiente, y en el que se asume que los valores de y_i pueden ser ajustados mediante una función lineal. El objetivo de SVR es encontrar los parámetros $w = (w_1, \dots, w_d)$ que definen dicha función de regresión f que mejor describe la salida observada y_i :

$$f(x) = (w_1 \cdot x_1 + \dots + w_d \cdot x_d) + b \quad (35)$$

Debido a que es difícil que los ejemplos de entrenamiento se ajusten a un modelo lineal con un error de predicción igual a cero, se recurre al concepto de margen blando. Para ello, se definen dos variables de holgura ξ_i^+ y ξ_i^- , que permiten cuantificar la magnitud del error (Suarez, 2014).

En el caso de que los ejemplos no puedan ajustarse por una función lineal se realiza una “*Kernelización*” de las SVR. Los ejemplos pertenecientes al espacio original de entradas se transforman mediante un mapeo no lineal en un nuevo espacio, denominado espacio de características, en el que sí es posible ajustar los ejemplos transformados mediante un regresor lineal (Suarez, 2014). Así, la regresión no lineal compleja del espacio de entrada se puede resolver teóricamente usando una regresión lineal simple (Gong, Zhang, Lan, & Wang, 2016):

$$f(x) = w \cdot \Phi(x) + b \quad (36)$$

donde Φ es una función no lineal por la cual x se mapea a un espacio de características; w es el vector de pesos o parámetros; y b es un bias constante. Los valores de w y de b son calculados mediante un problema de optimización.

3.4.4 Extreme Learning Machine (ELM)

La Máquina de Aprendizaje extremo o Extreme Learning Machine (ELM) es un algoritmo propuesto por Huang, Zhu, & Siew (2006) que toma como base la estructura de una red neuronal feed-forward con una sola capa (SLFN, del inglés Single-Layer Feedforward Network). ELM es una técnica de aprendizaje emergente que proporciona soluciones eficientes para redes feed-forward (redes de una sola

capa o múltiples capas ocultas), redes de función radial (RBF), y aprendizaje de kernel. Huang et al. (2006) demuestra la capacidad que tiene ELM para ser un aproximador universal donde los pesos de entrada son elegidos al azar y pueden ser generados de acuerdo a cualquier distribución de probabilidad continua, sin ningún conocimiento previo. El algoritmo ELM tiene un gran potencial como una técnica alternativa viable para la computación a gran escala y el aprendizaje automático (Cambria et al., 2013). ELM tiene varias ventajas en comparación con los tradicionales algoritmos de aprendizaje basados en el gradiente, como los algoritmos de *backpropagation* para redes neuronales feed-forward (Huang et al., 2006): (i) la velocidad de aprendizaje con ELM es mucho más rápida; (ii) ELM tiende a producir un mejor rendimiento de generalización; (iii) ELM permite que las redes neuronales feed-forward se pueden entrenar con funciones de activación no diferenciables; (iv) ELM tiende a alcanzar soluciones sin mínimo local, sobreajuste o aprendizaje inadecuado; (v) y es fácil de implementar y la intervención humana es mínima.

Una SLFN, o lo que es lo mismo, una MLP con una sola capa oculta queda definida por la siguiente ecuación basada en las ecuaciones 24-26:

$$\hat{y}_j = \sum_{i=1}^L \beta_i \cdot f(w_i \cdot x_j + \theta_i) + \beta_0 \quad (j = 1, \dots, N) \quad (37)$$

donde \hat{y}_j es la salida del modelo; N y L son el número de datos de entrada y de neuronas ocultas, respectivamente; β_i y β_0 son el peso y bias de la capa de salida; f es la función de activación; x_j es el input del modelo; y w_i y θ_i son el peso y bias en la capa oculta de L neuronas ocultas.

En el enfoque ELM para SLFN, primeramente los pesos (w_i) y los bias de la capa oculta (θ_i) de la ecuación 37 se pueden asignar aleatoriamente siempre que las funciones de activación de la capa oculta sean infinitamente diferenciables. Por lo tanto, solo deben optimizarse los parámetros β durante el proceso de entrenamiento. Sin embargo, según Huang (2014), el término β_0 no es necesario. El entrenamiento de una SLFN con ELM es un sistema lineal que simplifica el problema de encontrar la solución de mínimos cuadrados como:

$$H\beta = Y \quad (38)$$

donde H es la matriz de salidas de la capa oculta de dimensión $N \times L$; β es la matriz de pesos de las conexiones entre la capa oculta y de salida de dimensión $L \times m$, con m igual al número de neuronas de salida; e Y es la matriz de target (datos observados de salida) con dimensión $N \times m$. Finalmente, se calcula la matriz H ; y la matriz β es determinada analíticamente a través de la operación inversa generalizada de Moore-Penrose de la matriz H . La matriz de pesos óptimos de salida de la capa oculta $\hat{\beta}$ viene dada por:

$$\hat{\beta} = H^{\dagger} Y \text{ with } H^{\dagger} = PH^T \text{ and } P = (H^TH)^{-1} \quad (39)$$

donde H^{\dagger} es la matriz pseudo-inversa de Moore-Penrose de la matriz H , and P es la inversa de la matriz de covarianza de la matriz H .

3.5 FÓRMULAS EMPÍRICAS PARA CAUDALES MÁXIMOS INSTANTÁNEOS

En este apartado se describen las fórmulas utilizadas en la presente tesis para transformar los datos de caudales medios diarios en sus correspondientes caudales instantáneos. Como ya se introdujo en el capítulo 2, para abordar este problema, básicamente se han empleado dos enfoques diferentes. El primer enfoque incluye métodos que establecen una relación entre el Q_{ins} y el Q_{md} utilizando las características fisiográficas de la cuenca: el método propuesto por Fuller (1914) y por el CEDEX (2011). Y el segundo enfoque calcula el Q_{ins} a partir de una secuencia de datos de caudales medios diarios: las fórmulas propuestas por Sangal (1983) y por Fill & Steiner (2003).

3.5.1 Fuller

El estudio que realizó Fuller (1914) es uno de los primeros y más importantes que abordó este problema. Fuller estudió los datos de inundación de 24 cuencas hidrográficas de Estados Unidos, con áreas comprendidas entre 3.06 y 151592 km². Trazó la relación entre el exceso del caudal pico sobre el máximo caudal diario medio, el caudal máximo medio diario frente el área de drenaje y dibujó una curva promedio. Esta curva dio la siguiente relación, la cual hace depender la relación entre ambos caudales del área de la cuenca vertiente:

$$Q_{ins} = MQ_{md} \cdot (1 + 2.66 \cdot A^{-0.3}) \quad (40)$$

donde Q_{ins} es el caudal máximo instantáneo estimado en m^3/s , MQ_{md} es el caudal diario medio máximo observado en m^3/s , y A es el área de drenaje en km^2 . Los coeficientes presentes en la ecuación 40 son coeficientes de regresión que se obtuvieron en el estudio de Fuller (1914). Los parámetros de regresión de la fórmula de Fuller (Ecuación 40), 2.66 y -0.3, son los establecidos como referencia en la fórmula de Fuller, los cuales pueden variar entre 2.5 y 6, y en torno a -0.3, respectivamente, según los trabajos realizados por Fuller. Esta fórmula es quizá la más conocida de entre todas las expresiones matemáticas disponibles para transformar los caudales medios diarios en instantáneos (CEDEX, 2011).

3.5.2 Fórmulas del CEDEX (Regionalizaciones de la fórmula de Fuller)

CEDEX publicó en 2011 un informe técnico sobre las metodologías que utilizaron para la realización del mapa de caudales máximos de las diferentes cuencas hidrográficas españolas. CEDEX (2011) propuso doce fórmulas regionales para transformar los datos de MQ_{md} en el Q_{ins} correspondiente, basándose en el método de Fuller. Para ello, CEDEX realizó una calibración regional de dichos parámetros mediante regresión entre los caudales medios diarios y los instantáneos en estaciones de aforos con suficiente información. En la Tabla 3 se recogen las fórmulas obtenidas para las distintas zonas consideradas. En las cuencas correspondientes al Guadiana y al Guadalquivir se diferencia la zona 1 correspondiente a la cabecera del Guadiana hasta el río Jabalón incluido, la zona 2 con los afluentes del río Guadiana por su margen izquierda aguas abajo del río Olivenza y ríos Tinto y Odiel, y por último la zona 3 es la formada por el resto de la cuenca del río Guadiana y cuenca del río Guadalquivir. De la misma manera, las cuencas del río Ebro quedan divididas en tres zonas. La zona 1 es la formada por la cabecera del Ebro hasta los ríos Arga en la margen izquierda y Queiles en la derecha, ambos incluidos, la zona 2 está comprendida por el resto de la cuenca del Ebro por la margen izquierda, y la zona 3 por el resto de la cuenca del Ebro por la margen derecha.

Tabla 3. Fórmula de Fuller regionalizadas por CEDEX (2011) para doce cuencas de España.

Región	Fórmula
Miño-Sil + Galicia Costa	$Q_{ins} = MQ_{md} \cdot (1+1.81 \cdot A^{-0.23})$
Cantábrico + País Vasco	$Q_{ins} = MQ_{md} \cdot (1+3.1 \cdot A^{-0.26})$
Duero	$Q_{ins} = MQ_{md} \cdot (1+1.78 \cdot A^{-0.29})$
Tajo	$Q_{ins} = MQ_{md} \cdot (1+5.01 \cdot A^{-0.38})$
Guadiana y Guadalquivir (Zona 1)	$Q_{ins} = MQ_{md} \cdot (1+35.89 \cdot A^{-0.72})$
Guadiana y Guadalquivir (Zona 2)	$Q_{ins} = MQ_{md} \cdot (1+112.82 \cdot A^{-0.7})$
Guadiana y Guadalquivir (Zona 3)	$Q_{ins} = MQ_{md} \cdot (1+11.56 \cdot A^{-0.42})$
Júcar	$Q_{ins} = MQ_{md} \cdot (1+20.87 \cdot A^{-0.51})$
Segura	$Q_{ins} = MQ_{md} \cdot (1+145.85 \cdot A^{-0.75})$
Ebro (Zona 1)	$Q_{ins} = MQ_{md} \cdot (1+2.49 \cdot A^{-0.36})$
Ebro (Zona 2)	$Q_{ins} = MQ_{md} \cdot (1+3.39 \cdot A^{-0.29})$
Ebro (Zona 3)	$Q_{ins} = MQ_{md} \cdot (1+37.73 \cdot A^{-0.55})$

3.5.3 Sangal

Sangal (1983) propuso una fórmula basada en un hidrograma triangular donde las variables eran los caudales medios diarios de tres días consecutivos:

$$Q_{ins} = \frac{4 \cdot Q_2 - Q_1 - Q_3}{2} \quad (41)$$

donde Q_2 es el caudal medio diario del día en el que se produjo el caudal pico o caudal máximo instantáneo, por lo tanto Q_2 es igual al MQ_{md} ; Q_1 es el caudal medio diario del día anterior en el que se dio el Q_2 ; y el Q_3 es el caudal medio diario del día posterior al día de Q_2 . Todo en m^3/s . Sangal testeó su método utilizando 3946 datos anuales recogidos en 387 estaciones de caudales de Ontario (Canadá). Las cuencas estudiadas tenían una superficie comprendida entre menos de 1 y más de 100000 km^2 . Y se obtuvieron buenas predicciones en la mayoría de ellas, aunque en las cuencas pequeñas el flujo máximo se subestimaba.

3.5.4 Fill-Steiner

Fill & Steiner (2003) realizaron un estudio basado en la fórmula de Sangal y obtuvieron valores de Q_{ins} que sobreestimaban los valores observados en áreas de superiores a 1000 km^2 . Este problema de la sobreestimación del flujo máximo

instantáneo llevó a Fill & Steiner a proponer una mejora del método de Sangal. Utilizaron datos de 14 estaciones de cuencas con área de drenaje comprendidas entre 84 y 687 km² en Brasil y desarrollaron una fórmula adecuada para áreas de drenaje de 50 a 700 km², similar a la de Sangal (Ecuación 41) para obtener el Q_{ins} empleando los datos de caudales medio diarios de tres días consecutivos.

$$Q_{ins} = \frac{0.8 \cdot Q_2 + 0.25 \cdot (Q_1 + Q_3)}{0.9123 \cdot (Q_1 + Q_3)/2 + 0.362} \quad (42)$$

Donde, al igual que en la fórmula de Sangal, Q_2 es el caudal medio diario del día en el que se produjo el caudal pico o caudal máximo instantáneo, por lo tanto Q_2 es igual al MQmd; Q_1 es el caudal medio diario del día anterior en el que se dio el Q_2 ; y el Q_3 es el caudal medio diario del día posterior al día de Q_2 .

IV – PUBLICACIONES

IV – PUBLICACIONES

En este capítulo se presentan las publicaciones que forman parte de esta tesis. Esta tesis se puede dividir en cuatro partes o etapas, cada una de ellas con su correspondiente artículo publicado, excepto el cuarto artículo que aún se encuentra bajo revisión.

- **Publicación 1:** La primera parte de esta investigación fue la simulación de las series de caudales utilizando SWAT y RNAs. Estos dos modelos fueron empleados para simular el proceso de lluvia-escorrentía y sus resultados fueron comparados para evaluar su rendimiento. SWAT cuenta con un gran número de parámetros, y a su vez estos con un gran rango de valores, lo que hace que su calibración sea compleja. Para facilitar el proceso de calibración de SWAT se empleó el software SWAT-CUP. Es un programa independiente que contiene varios algoritmos de calibración. En cuanto al modelo de RNA, se analiza el comportamiento de diferentes arquitecturas de red con diferentes variables de entrada, para así encontrar la estructura que mejor funciona para cada cuenca. El reto de los modelos hidrológicos es representar adecuadamente todas las fases de caudales con el mismo conjunto de parámetros del modelo, evitando subestimar los caudales muy elevados y, por lo tanto, el riesgo de inundación, y por otro lado evitar sobreestimar los caudales muy bajos lo que supondría problemas en el suministro de agua. Por lo tanto, para una evaluación más completa, la precisión de estos modelos en la estimación de caudales fue evaluada por separado para los diferentes tipos de flujo, las curvas de duración de caudales (CDCs) fueron empleadas para este propósito. Específicamente, las CDCs se dividieron en cinco zonas: caudales muy bajos, bajos, medios, altos, y muy altos. Esta segmentación permite el análisis de eventos de caudales importantes con mayor precisión. En este estudio fueron dos las zonas de estudio seleccionadas, dos cuencas hidrográficas de España con condiciones climáticas contrastadas: la cuenca del río Ladra con clima atlántico y la cabecera de la cuenca del río Segura con un

clima mediterráneo. Estas cuencas se seleccionaron en base a la gran diversidad de condiciones climáticas que representan, una de las áreas más lluviosas de Europa en el noreste de España y una de las áreas más áridas en el sureste de España. Para garantizar la validez de los resultados, ambas cuencas están en régimen natural. Seleccionar el modelo apropiado para simular el flujo de agua en una cuenca hidrográfica es un desafío clave, y analizar el rendimiento de estos modelos en diferentes cuencas climáticas podría ayudar a los investigadores a aplicar el modelo adecuado en cada caso.

- **Publicación 2:** En la segunda parte de la presente tesis se lleva a cabo la estimación de caudales máximos instantáneos a partir de datos diarios. Se comparan los resultados obtenidos con las fórmulas empíricas de Fuller, Sangal, Fill-Steiner, y las elaboradas por el CEDEX, con los obtenidos con dos técnicas de machine learning, las RNAs y ANFIS. Estos métodos se aplican en catorce estaciones de aforo que cubren la gran diversidad de condiciones de torrencialidad encontradas en la España peninsular.
- **Publicación 3:** En la tercera parte de esta investigación se hace una combinación de las dos primeras partes. Una vez comprobado que SWAT es válido para simular caudales diarios y que las técnicas de machine learning son adecuadas para la estimación de caudales máximos instantáneos, se propuso y se validó un enfoque para estimar los caudales máximos instantáneos mediante la combinación de SWAT y de machine learning. Este estudio se realizó en una cuenca hidrográfica. El modelo SWAT se empleó para estimar los caudales diarios. A partir de los caudales máximos diarios, se entrenaron cuatro modelos de inteligencia artificial, como las RNAs, ANFIS, SVM y ELM, para estimar los caudales instantáneos.
- **Publicación 4:** De forma paralela a las otras tres publicaciones se ha llevado a cabo un estudio para la simulación de caudales en cuencas con importantes procesos nivales. Para ello se desarrolló un modelo formado por el acoplamiento de un modelo de nieve al modelo de Témez. Se analizó el comportamiento de este modelo y se comprobó la necesidad de corregir los datos de precipitación. Los pluviómetros modifican los campos de viento, produciendo una captura insuficiente de la precipitación sólida. Por esta razón, las mediciones de precipitación sólida muestran importantes sesgos con respecto a los valores reales, especialmente en condiciones de viento. En

este trabajo se propone una metodología que combina modelos geoestadísticos e hidrológicos para realizar una evaluación preliminar de del *under-catch* global en regiones alpinas. Se basa en la información disponible sobre el caudal en régimen natural diario y en los datos climáticos diarios (precipitación y temperatura) de la cuenca. Se analizan largos periodos de tiempo para tener en cuenta el comportamiento estocástico del flujo de la corriente natural y las variables climáticas. Se realizó una evaluación preliminar de los campos de temperatura y precipitación aplicando diferentes enfoques geoestadísticos asumiendo algunas hipótesis sobre la relación entre los campos climáticos y la altitud. Los campos generados se emplearon como entradas de un modelo hidrológico conceptual, que incluye dos parámetros para corregir, respectivamente, la precipitación sólida y líquida. Los parámetros se calibran minimizando la diferencia entre los caudales simulados e históricos. El modelo fue validado y sus resultados permitieron alcanzar los siguientes objetivos: identificar la mejor combinación de modelos geoestadísticos e hidrológicos para aproximar caudales, realizar una evaluación global del *under-catch* en la precipitación sólida y líquida, e identificar y analizar el patrón de precipitación, en términos de distribución entre precipitación sólida y líquida y gradientes de precipitación con la altura. Se ha aplicado en la Cuenca de Canales, una cuenca alpina de Sierra Nevada (España).



4.1 PUBLICACIÓN 1: A COMPARISON OF SWAT AND ANN MODELS FOR DAILY RUNOFF SIMULATION IN DIFFERENT CLIMATIC ZONES OF PENINSULAR SPAIN

Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., y Pulido-Velazquez, D. (2018). A Comparison of SWAT and ANN Models for Daily Runoff Simulation in Different Climatic Zones of Peninsular Spain. *Water*, 10(2), 192.
<https://doi.org/10.3390/w10020192>



Article

A Comparison of SWAT and ANN Models for Daily Runoff Simulation in Different Climatic Zones of Peninsular Spain

Patricia Jimeno-Sáez ^{1,*}, Javier Senent-Aparicio ¹ , Julio Pérez-Sánchez ¹  and David Pulido-Velazquez ^{1,2}

¹ Department of Civil Engineering, Catholic University of San Antonio, Campus de los Jerónimos s/n, Guadalupe, 30107 Murcia, Spain; jsenent@ucam.edu (J.S.-A.); jperez058@ucam.edu (J.P.-S.); d.pulido@igme.es (D.P.-V.)

² Geological Survey of Spain (IGME), Granada Unit, Urb. Alcázar del Genil, 4. Edificio Zulema, 18006 Granada, Spain

* Correspondence: pjimeno@ucam.edu; Tel.: +34-968-278-818

Received: 18 December 2017; Accepted: 9 February 2018; Published: 11 February 2018

Abstract: Streamflow data are of prime importance to water-resources planning and management, and the accuracy of their estimation is very important for decision making. The Soil and Water Assessment Tool (SWAT) and Artificial Neural Network (ANN) models have been evaluated and compared to find a method to improve streamflow estimation. For a more complete evaluation, the accuracy and ability of these streamflow estimation models was also established separately based on their performance during different periods of flows using regional flow duration curves (FDCs). Specifically, the FDCs were divided into five sectors: very low, low, medium, high and very high flow. This segmentation of flow allows analysis of the model performance for every important discharge event precisely. In this study, the models were applied in two catchments in Peninsular Spain with contrasting climatic conditions: Atlantic and Mediterranean climates. The results indicate that SWAT and ANNs were generally good tools in daily streamflow modelling. However, SWAT was found to be more successful in relation to better simulation of lower flows, while ANNs were superior at estimating higher flows in all cases.

Keywords: Soil and Water Assessment Tool (SWAT); Artificial Neural Network (ANN); data imputation; runoff simulation; hydrologic modelling

1. Introduction

Streamflow is one of the most important variables of the hydrological cycle. In a watershed, streamflow data are necessary for many water resources issues such as management, planning and hydraulic engineering design [1]. Hydrological models are used in science and practice to predict extreme events in terms of flood and low-flow events for river management [2]. Therefore, a challenge of hydrological models is to adequately represent all phases with the same model parameter set [3] to avoid underestimating the very high flow and therefore the risk of flooding and to avoid overestimating the very low flow and water supply problems. There are many hydrological models. Conceptual hydrologic models that simulate streamflow in a watershed take into consideration various processes of the hydrological cycle through mathematical formulation [4]. Numerous hydrologic models have been developed to simulate the hydrologic processes and are important tools for estimating streamflow values, capable of establishing rainfall-runoff relationships [5]. A sophisticated mathematical model is the Soil and Water Assessment Tool (SWAT) [6]. SWAT is a conceptual semi-distributed model and currently is one of the most popular hydrologic models for watershed scale [7]. It has been widely

used to estimate the streamflow time series and requires a large amount of spatial and temporal data and input parameters. In addition, the broad range of value parameters and their complex interactions complicate the model parameterization and calibration process [4]. To facilitate this process, SWAT-CUP (Calibration and Uncertainty Procedures) has been developed. It is a stand-alone program developed for calibration of SWAT which contains five calibration procedures and includes functionalities for validation and sensitivity analysis [8].

On the other hand, over the last decades with advances in computing, the estimation of hydrological variables by machine learning has gained much attention among researchers. Recent studies about real-life cases using soft computing techniques in hydrologic engineering consist of the following: Olyaie et al., (2015) [9] compared three artificial intelligence approaches, namely, artificial neural networks (ANNs), adaptive neuro-fuzzy inference system (ANFIS) and coupled wavelet and neural network (WANN), for estimating suspended sediment load (SSL) of river systems; Gholami et al., (2015) [10] modelled of groundwater level fluctuations using dendrochronology (tree-rings) and an ANN; Chen and Chau (2016) [11] developed a hybrid double feedforward neural network model for daily SSL estimation; Jimeno-Sáez et al., (2017) [12] used different machine learning models, such as ANN and ANFIS for instantaneous peak flow estimation based on maximum mean daily flow.

Specifically, ANNs, which have been introduced and widely applied to water resources system problems, were found to be powerful tools for the estimation of streamflow time series [13,14]. The particular advantage of the ANN is that the network can be trained to learn these relationships without requiring a priori knowledge of the physical characteristics of the process [15]. This feature makes ANNs an effective tool for modelling complex hydrological processes [16]. ANNs are empirical models which can be used as an alternative to simulate hydrological processes by connecting inputs and outputs through mathematical functions without the need to know the relationship with the catchment characteristics [17]. ANNs have been used in a considerable number of recent studies for estimating the values of streamflow [4,12,18–20]. Therefore, SWAT and ANN have been widely used for streamflow estimation. However, few studies have compared both models for daily streamflow estimation [5,21–23].

Against this background, one of the goals of this work is to use SWAT and ANNs to build a hydrologic model in basins with contrasting climatic conditions to simulate streamflow. These models are assessed at basin scale and in daily time intervals. A comparison of performance of ANN models with different input variables (e.g., daily precipitation, daily precipitation of previous days, total precipitation of previous days, mean daily temperature) has been made to find the best and most efficient network structure. Secondly, the selection of the most appropriate model for each of the studied cases is analysed by comparing the performance of SWAT and ANN models. In addition, their efficiency for the estimation of different ranges of flow (from very high to very low flow) is determined based on the flow duration curve (FDC). Thus, the efficiency of these models has been assessed in two watersheds: the Ladra River Basin (LRB) with an Atlantic climate and the headwaters of the Segura River Basin (HSRB) with a Mediterranean climate. These basins were selected based on the wide diversity of climate conditions that they represent, including some of the rainiest areas in Europe in the northeast of Spain (LRB) and the driest areas in the southeast of Spain (HSRB). To ensure the validity of the results, both basins are in natural regime. Selecting the appropriate model to simulate the streamflow in a watershed is a key challenge, and analysing the performance of these models in different climate basins could help researchers to apply the suitable model in each case.

2. Materials and Methods

2.1. Study Areas and Data Inputs

To compare the accuracy of SWAT and ANN models, two contrasting watersheds in Spain were selected as case studies in this work. Figure 1 shows the location map and the digital elevation models (DEMs) of the watersheds. Table 1 summarizes the characteristics of both watersheds. LRB is located in

the north of the Miño-Sil Basin (NW Spain) and covers an area of 843 km² with an elevation range from 392 to 872 m asl. The climate is typical Atlantic, with higher differences between extreme temperatures in summer and winter. Annual precipitation ranges from 660 to 1632 mm. The streamflow data are abundant and are produced by persistent Atlantic frontal systems from the west that generally occur from autumn to spring; summer is the driest season [24]. The mean monthly flow varied from 48 m³/s in winter to 4 m³/s in summer; this flow gradually decreases until summer and increases again during autumn. The predominant soil type is Humic Cambisol (82% of the total area). This area has a low permeability, and the importance of aquifers is much lower than superficial water resources [25]. The major land cover in the Ladra River watershed is forest land (35%) followed by land with scrub and/or herbaceous vegetation (24%), heterogeneous agricultural areas (23%) and mixed mosaic (18%).

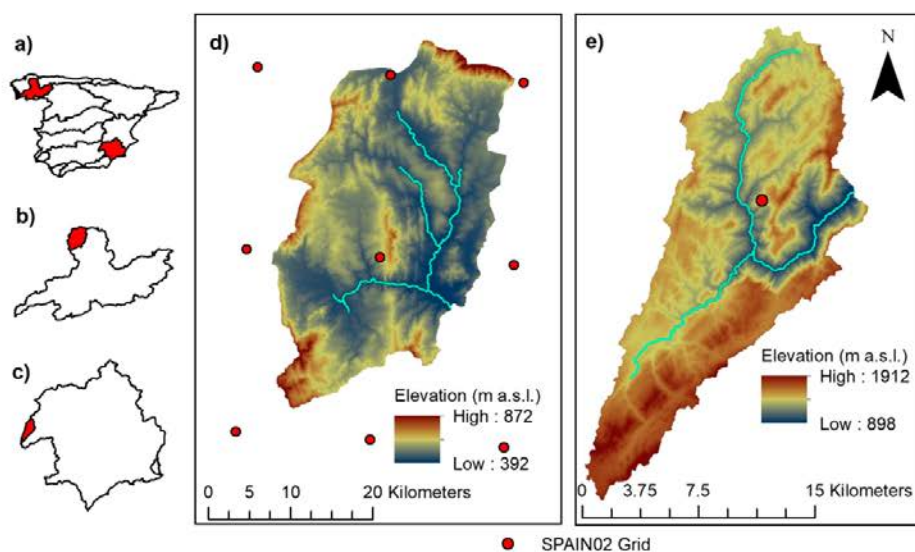


Figure 1. (a) Location of the Miño-Sil and Segura River Basins in Peninsular Spain; (b) Location of the LRB in the Miño-Sil River Basin; (c) Location of the HSRB in the Segura River Basin; (d) DEM of the LRB; (e) DEM of the HSRB.

Table 1. Characteristics of the watersheds.

Characteristic	LRB ¹	HSRB ²
Mean annual temperature (°C)	11.2	13.2
Mean annual precipitation (mm)	1218	748
Mean annual flow (m ³ /s)	23.66	1.85

¹ According to data from 1971 to 2007. ² According to data from 1987 to 2007.

The other studied area is the headwaters of the Segura River Basin (SE Spain), which has an area of 235 km² and is characterized by steep terrain with an elevation range from 898 to 1912 m asl. The climate is Mediterranean with very dry summers and a rainy season extending from October to May, during which over 80% of annual precipitation occurs. The mean annual precipitation ranged from 412 to 1234 mm. The main soil type is Rendzic Leptosol (88% of the total area) with good drainage [26]. The catchment is characterized by conditions which allow the infiltration of a large amount of water and which smooth the hydrological response, and groundwater is crucial in surface hydrology [27]. During the summer months the rainfall is practically non-existent, and so the streamflow in this period is mainly from groundwater sources [28]. The mean monthly flow varies

between $0.96 \text{ m}^3/\text{s}$ in September and $2.97 \text{ m}^3/\text{s}$ in January. The HSRB is a mostly forest-dominated area which covers about 61% of the basin, and 19% is covered by Mediterranean scrubland vegetation.

The SWAT and ANN models were constructed using freely available information. The daily discharge data of LRB were collected from the Centre for Hydrographic Studies of CEDEX website [29] and are available from 1971. The daily flow data for HSRB are available on the Hydrographic Confederation of the Segura River website [30] from 1987. This work used the climatic database SPAIN02 (see details in Herrera et al., (2012) [31]), which includes daily precipitation and temperature data for 1950 to 2007 in a grid ($20 \times 20 \text{ km}$) for Spanish territory. This grid was developed by considering a very dense network of quality-controlled stations. The grid was produced applying the kriging method in a two-step process. First, the occurrence was interpolated using a binary kriging and, in a second step, the amounts were interpolated by applying ordinary kriging to the occurrence outcomes [31]. Distributed hydrological models require spatially long-term, distributed, continuous data to simulate the hydrological response of a basin. However, conventional weather stations cannot fully represent the climate conditions across a basin because they are often sparsely distributed, particularly if large hydro climatic gradients exist [32]. In addition, weather station records often do not cover the proposed simulation period or contain gaps. That is why we have used grid-based data. DEMs were obtained from the National Geographic Institute of Spain [33], with a resolution of 25 m. The soil data were obtained from the Harmonized World Soil Database (HWSD), assembled by the Food and Agriculture Organization of the United Nations (FAO) [34]. Land cover maps were extracted from reclassified Corine Land Cover (CLC) [35].

2.2. SWAT Model

SWAT is a semi-distributed and semi-physically based model. SWAT considers the heterogeneity of a watershed by dividing it into sub-watersheds based on the river network and topography; subsequently, sub-watersheds are divided into hydrologic response units (HRUs) which lump land areas with unique soil, land cover and slope combinations. SWAT simulates the hydrologic cycle based on water balance, which is controlled by climate inputs such as daily precipitation and maximum and minimum air temperature. The water balance equation employed is [6]:

$$SW_t = SW_{init} + \sum_{i=1}^t (R_{day}(i) - Q_{surf}(i) - E_a(i) - W_{seep}(i) - Q_{gw}(i)) \quad (1)$$

where SW_t is the final soil water content (mm), SW_{init} is the initial soil water content (mm), t is the time in days, $R_{day}(i)$ is the precipitation on day i (mm), $Q_{surf}(i)$ is the surface runoff (mm), $E_a(i)$ is the evapotranspiration (mm), $W_{seep}(i)$ is the percolation (mm) and $Q_{gw}(i)$ is the amount of baseflow (mm).

2.2.1. Model Setup and Data Sets

The SWAT model requires physically based inputs, like hydro-meteorological data, topography, soil properties, and land-use/land-cover in the catchment. Daily precipitation data (mm) and maximum and minimum temperature ($^{\circ}\text{C}$) data from 1971 to 2007 in LRB and from 1987 to 2007 in Segura Basin were used for the SWAT model simulation. Relative humidity, solar radiation and wind speed were not available in the study areas. In this study, we simulated the potential evapotranspiration using the Hargreaves method [36] because it only requires maximum and minimum daily temperatures. Besides, according to Schneider et al., (2007) [37], the potential evapotranspiration method adopted has a minor effect on the simulated discharge response. The DEMs, with a 25 m mesh size, were used to determine the watershed and sub-watershed boundaries. Soil maps were used to characterize each soil type from information on soil texture, hydraulic conductivity and available water content, among others. Land cover is one of the most important factors that controls events such as runoff, evapotranspiration, sediment deposition and soil erosion [38]. In SWAT, the combination of these three data sets (DEM, soil maps and land cover maps) divided the watersheds into HRUs; three categories of

slope were defined (0–8%, 8–30% and >30%) to characterize the variety of the surface, and a threshold level of 10% was established to simplify model processing and remove minor slopes, soils and land used for each sub-watershed. Finally, LRB has been divided into 11 sub-basins and 124 HRUs and HSRB into 3 sub-basins and 21 HRUs.

2.2.2. Sensitivity Analysis, Calibration and Validation

Sensitivity analysis and calibration of parameters of the SWAT model were carried out automatically in SWAT-CUP using the SUFI-2 algorithm [39]. Sensitivity analysis allowed us to calculate the rate of change in model output with respect to changes in model parameters [40] and thus we were able to identify the most influential parameters in governing streamflow [41]. The parameters were calibrated using the observed daily discharge; the process consists in adjusting them so that the daily simulations are as close as possible to the observations. Firstly, we performed 500 model runs to obtain the sensitivities, and the most sensitive parameters were identified for each basin. Afterwards, two iterations of 1500 simulations were run as recommended by Yang et al., (2008) [42], readjusting the parameters after the second iteration. The input data series were divided into three phases: warm-up, calibration and validation. In the LRB, the period from 1971 to 1989 was chosen for model calibration, preceded by a five-year warming period (1966–1970). After calibration, the model was validated using daily streamflow from 1990 to 2007. For HSRB, the periods of 1987–1997 and 1998–2007 were used for model calibration and validations, respectively, also preceded by a five-year warm-up.

2.3. Artificial Neural Network

An ANN is a computing method with a mathematical structure which mimics the human brain and nervous system. This network learns, memorizes and discloses the various relations found in the data. It is capable of modelling complex nonlinear input/output time-series relationships of a watershed without prior and explicit knowledge of the physical characteristics of that process [17,18]. ANNs are composed of neurons or processing units which are organized in layers and connected through several links. There are many different architectures of ANNs: single-layer and multilayer networks according to the number of layers and feed-forward, recurrent and self-organizing networks according to the direction of information flow and processing. In this work, we have used the multilayer feed-forward networks, which are the most widely applied to simulate hydrological processes (e.g., [1,9,10,18]) and consist of a number of neurons organized in an input layer, one or more hidden layers and an output layer [20]. The input layer includes neurons where input data are fed into the network. In the hidden layers, the neurons receive signals only from neurons in the previous layer and process data. Finally, the outputs are produced for the given inputs in the output layer. The nodes are connected to nodes in the neighbouring layers by weighted synaptic connections; each link has an associated weight that represents its connection strength. These weights store the knowledge of the network, that is, they parameterize the mathematical relationships between the variable inputs of the network; positive weight values reflect excitatory connections, negative values mean inhibition connections, whereas the zero weights make the connection considered non-existent. The scheme of operation of these networks is as follows: (i) The information is processed in the neurons, each neuron receives an array of inputs or signals; (ii) these signals pass between neurons through connection links; (iii) each neuron forms a linear combination of the signals' inputs according to its weights and then passes through an activation function to produce an output signal [43]. The mathematical operation of a neuron is given as Equation (2):

$$y_j = f \left(\sum_{i=1}^n x_i \cdot w_i - b_j \right) \quad (2)$$

where y is the output of a neuron j , f is an activation function, x_i is an input of the vector of inputs ($i = 1, 2, \dots, n$), w_i is the weight associated with the connection link through which the input x_i arrives

to current neuron j from a neuron in the preceding layer and b_j is a bias associated with neuron j . The activation function is usually a continuous and bounded nonlinear transfer function and controls the amplitude of the output neuron. The logistic sigmoid and hyperbolic tangent functions are the most commonly used in the hidden layers with a range of output from 0 to 1 and from -1 to 1, respectively [5], while a linear activation function may be used in the output layer so that a limited output interval has not been generated. The training process involves giving known input data and targets to the network and adjusting internal parameters (weight and biases) based on the performance measure and other parameters.

The ANN Modelling Approach

According to Govindaraju (2000) [43], there is no fixed method for determining the number of input-output data that will be required. An optimal data set should be representative of the probable occurrence of an input vector and should facilitate the mapping of the underlying nonlinear process. Inclusion of unnecessary patterns could slow network learning. In contrast, an insufficient data set could lead to poor learning. A typical ANN training requires three data sets: training, validation and testing [21]. In this work, the calibration data sets (1971 to 1989 in LRB, and 1987 to 1997 in HSRB) were divided into training sets (70% of data), validation data sets (15% of data) and testing data sets (15% of data). We have used a backpropagation algorithm to train, in which the result of the network (output of ANN model) is compared to the actual target (observed data), and then the network error is calculated. The output errors are repeatedly propagated backwards through the network to adjust its parameters until optimal values are obtained [1]. The training was finished when the error on the validation data sets was near minimum. There are several backpropagation algorithms to network training. The superiority of the Levenberg-Marquardt (LM) algorithm [44,45] over other algorithms for better performance (lower estimated error) and higher convergence speed (when determining epoch size) was clearly established in several studies (e.g., [46,47]). LM is often the fastest backpropagation algorithm. Studies about streamflow forecasting [47,48] have shown that the LM algorithm has an appropriate operation in training this type of network. Therefore, LM algorithm has been used to reduce the mean squared error (MSE) (Equation (3)) iteratively in this study:

$$\text{MSE} = \frac{\sum_{i=1}^n (O_i - E_i)^2}{n} \quad (3)$$

where O_i is the ANN target (observation), E_i is the ANN output (simulated value) and n is the total number of observations. For use in finding optimal neural weights by backpropagation algorithms based on a least-squared approach such as MSE, it is required that the transfer function be easily differentiable, thus permitting the evaluation of increments of weights via the chain rule for partial derivatives [49]. According to Dawson and Wilby (2001) [50], the logistic sigmoid is continuous and relatively easy to compute (as is its derivative). Thus, we used a feed-forward neural network with LM back-propagation learning and sigmoid transfer function, which is one of the best selections for modeling hydrologic parameters [10].

Different types and numbers of inputs were employed in the ANNs to estimate daily flow. Understanding the temporal relationships between climatic variables and streamflow is fundamental for ANN development. Many studies use time-series correlation analysis to determine the dependency between the observed streamflow and the antecedent climate variables [1,18,20]. In an attempt to check any overfitting, a cross-validation was performed. We divided the data sets into five subsets: four subsets were used to train, and the remaining subset was used to validate.

2.4. Evaluation Criteria for Model Comparison

In the cross-validation of the ANNs, we obtained the average performance for the five cross-validation steps. The selected networks for each basin were the best performances in terms of Nash-Sutcliffe efficiency coefficient (NSE), percent bias (PBIAS) and root mean squared error (RMSE).

The results were evaluated statistically using the statistics defined in Table 2. We have evaluated and compared SWAT and ANN results based on four statistics including NSE, PBIAS, RMSE and coefficient of determination (R^2), which are the most widely used in hydrology studies. These statistics are defined in Table 2.

Table 2. Performance metrics.

Equation	Range
$NSE = 1 - \frac{\sum_{i=1}^n (O_i - E_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$	$[-\infty, 1]$
$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}) \cdot (E_i - \bar{E})]^2}{\left[\sum_{i=1}^n (O_i - \bar{O})^2 \right]^{0.5} \cdot \left[\sum_{i=1}^n (E_i - \bar{E})^2 \right]^{0.5}}$	$[0, 1]$
$PBIAS = \frac{\sum_{i=1}^n (O_i - E_i) \cdot 100}{\sum_{i=1}^n (O_i)}$	$[-\infty, \infty]$
$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - E_i)^2}{n}}$	$[0, \infty]$

O_i is the i th observed data, \bar{O} is the mean of the observed data, E_i is the i th estimated data, \bar{E} is the mean of the estimated data and n is the total number of observations.

NSE indicates how well the plot of observed versus simulated data fits the 1:1 line and is recommended because it is very commonly used, which provides extensive information on reported values [51]. R^2 describe the degree of collinearity between simulated and measured data. PBIAS measures the average tendency of the simulated data to be larger or smaller than their observed counterparts and has the ability to clearly indicate poor model performance [52]. RMSE quantifies the prediction error in terms of the units of the variable calculated by the model. The best performance for NSE and R^2 is 1, and for PBIAS and RMSE the best performance is 0. In addition, to evaluate models we have used the criteria proposed by Kalin et al., (2010) [53], who adapted the monthly criteria of Moriasi et al., (2007) [51] to a daily scale (Table 3). In this case, the study is an exploratory analysis of the power of SWAT and ANN models for daily simulation of runoff, and this is an additional reason to relax the performance ratings according to the American Society of Agricultural and Biological Engineers (ASABE, 2017) [54].

Table 3. Evaluation model criteria for daily time scale.

Performance Rating	NSE	PBIAS (%)
Very good	$NSE \geq 0.7$	$ PBIAS \leq 25$
Good	$0.5 \leq NSE < 0.7$	$25 < PBIAS \leq 50$
Satisfactory	$0.3 \leq NSE < 0.5$	$50 < PBIAS \leq 70$
Unsatisfactory	$NSE < 0.3$	$ PBIAS > 70$

The results were also evaluated graphically using scatter plots. In addition to these goodness-of-fit measures, we analysed the results based on the flow duration curves to help visualize graphically the differences between observed and estimated streamflow. Pfannerstill et al., (2014) [2] presented an approach to improve the models' evaluation by subdividing the flow duration curve into different segments. Their results showed that the segmentation of very low/high and low/high flow allows analysis of the model performance for every important discharge event precisely. In addition, they concluded that the additional segmentation of the flow duration curve into low and very low flows is essential for taking into account long low flow periods events. In this study, to assess different phases of the hydrograph, FDCs were divided into five segments as shown in Table 4 according to Pfannerstill et al., (2014) [2], where Q_p represents the flow with a probability of exceedance equal

to $p\%$. The RMSE, defined in Table 2, was used to compare the performance of models for each hydrograph phase.

Table 4. Definition of five segments of different phases of the hydrograph.

Hydrograph Phase	Definition
Very high flow	Flows greater than Q5
High flow	Flows between Q5 and Q20
Medium flow	Flows between Q20 and Q70
Low flow	Flows between Q70 and Q95
Very low flow	Flows smaller than Q95

3. Results and Discussion

3.1. Sensitive Analysis, Calibration and Validation of the SWAT Model

A global sensitivity analysis was conducted to identify the most important influence parameters for streamflow simulation, which were adjusted during calibration. A ranking of parameter sensitivities was obtained after 500 model runs. The effect of the parameters on the simulated streamflow was evaluated with p -value which determines the significance of the sensitivity and t -stat which provide a measure of sensitivity. The ranking of most sensitive parameters observed in this study (Table 5) was also supported by the findings of Raposo et al., (2013) [55] in the LRB and Senent-Aparicio et al., (2017) [26] in the HSRB. Some of the most sensitive parameters are common for both basins with a similar order of sensitivity, as for example ALPHA_BF, CH_N1, CH_N2, SOL_K, CN2 and GWQMN.

Table 5. Sensitivity analysis of SWAT model parameters for LRB and HSRB.

Parameter	Definition	LRB			HSRB		
		t -Stat	p -Value	Rank	t -Stat	p -Value	Rank
ALPHA_BF	Baseflow alpha factor (days ⁻¹)	21.87	0.00	1	0.95	0.34	14
CH_N1	Manning's "n" value for the tributary channels	12.73	0.00	2	9.23	0.00	1
OV_N	Manning's "n" value for overland flow	5.98	0.00	3	1.23	0.22	12
GW_DELAY	Groundwater delay time (days)	-5.45	0.00	4	-0.91	0.36	15
CH_N2	Manning's "n" value for main channel	2.59	0.01	5	2.08	0.04	7
SOL_K	Saturated hydraulic conductivity (mm/h)	2.48	0.01	6	2.09	0.04	6
CN2	SCS runoff curve number	2.42	0.02	7	-8.09	0.00	2
GWQMN	Threshold depth of water in the shallow aquifer for return flow to occur (mm)	1.97	0.05	8	2.01	0.04	9
CH_K1	Effective hydraulic conductivity in tributary channel alluvium (mm/h)	-1.78	0.08	9	3.90	0.00	4
RCHRG_DP	Deep aquifer percolation fraction	-1.77	0.08	10	-2.05	0.04	8
LAT_TTIME	Lateral flow travel time (days)	-1.49	0.14	11	-2.16	0.03	5
SOL_AWC	Available water capacity of the soil layer (mm H ₂ O/mm soil)	1.34	0.18	12	5.39	0.00	3
BIOMIX	Biological mixing efficiency	1.23	0.22	13	0.80	0.42	16
SLSUBBSN	Average slope length (m)	1.21	0.23	14	0.25	0.80	20
GW_REVAP	Groundwater "revap" coefficient	1.11	0.27	15	1.41	0.16	10
SURLAG	Surface runoff lag coefficient	1.01	0.31	16	0.37	0.71	19
REVAPMN	Threshold depth of water in the shallow aquifer for "revap" or percolation to the deep aquifer to occur (mm)	0.93	0.36	17	1.20	0.23	13
CANMX	Maximum canopy storage (mm)	0.47	0.64	18	1.26	0.21	11
ESCO	Soil evaporation compensation factor	-0.20	0.84	19	-0.42	0.67	18
EPCO	Plant uptake compensation factor	0.01	0.99	20	0.69	0.49	17

After performing a global sensitivity analysis, the most sensitive parameters were selected for each studied basin, which are shown and defined in Table 6. All the selected parameters were also selected as the most relevant in other research [23,26,41,55].

Table 6. Parameters used in the SWAT model calibration in LRB and in HSRB.

Parameter	Range	Fitted Value	
		LRB	HSRB
GWQMN	0–5000	82.50	642.17
GW_DELAY	0–500	2.52	1.38
RCHRG_DP	0–1	0.01	0.70
ALPHA_BF	0–1	0.09	0.20
GW_REVAP	0.02–0.2	-	0.14
REVAPMN	0–1000	-	65.59
CH_K1	0–300	6.98	230.73
CH_N2	0.01–0.3	0.13	0.30
CH_N1	0.01–0.3	0.19	0.12
CN2	±20%	−1.35%	−3.75%
SOL_K	±20%	+12.01%	−12.04%
SOL_AWC	0–1	−1.29%	−5.51%
ESCO	0.1–1	0.77	0.39
SLSUBBSN	±20%	−0.57%	-
OV_N	0.01–0.8	0.69	-
LAT_TTIME	0–180	3.95	6.79
BIOMIX	0–1	0.94	-
CANMX	0–100	-	4.71

The fitted values of these parameters reflect the contrasting climatic characteristics of the two basins. In HSRB, groundwater parameters (GWQMN, GW_DELAY, RCHRG_DP, ALPHA_BF and GW_REVAP) were significant, as expected in Mediterranean basins where the aquifers are relevant [41,56]. A high deep aquifer percolation fraction (RCHRG_DP) and very low delay time (GW_DELAY) for aquifer recharge reflect the highly permeable geology of HSRB. In contrast, no relevant aquifer is present in LRB, where RCHRG_DP was very low. In both basins, the low values of ALPHA_BF indicate a slow response [57]. The low value of CH_K1 in LRB indicated a moderate loss rate for soil with high silt-clay content, while a high value in HSRB reflected a very high loss rate for very clean gravel and large sand [57]. Another big difference between the two basins is the soil evaporation compensation factor (ESCO). The ESCO was higher in the LRB, with an Atlantic climate, than in the HSRB, with a Mediterranean climate where evapotranspiration has a higher relevance [26]. When the ESCO value decreases, the ability of the model to extract the evaporative demand from lower soil layers increases [58]. Lateral flow travel time (LAT_TTIME) in the LRB was very similar to that used by Raposo et al., (2013) [55] in nearby basins where a significant portion of groundwater flows laterally as interflow [59]. The value of GWQMN was calibrated as 82.5 in LRB similar to that obtained in a nearby study [55]. Besides, an automated digital filter programme (Base Flow Filter Program) [60] was applied to determine the groundwater ratio. The results obtained are similar to those simulated by our model.

3.2. Input Selection, Training and Validation of ANN Models

Determining the input variables has a significant influence on the simulated flow. The basin rainfall and temperature data used by the ANNs were calculated using the Thiessen method, in which the climate values were based on a weighted average of the contribution of the cell in the area. After reviewing other research [22,23,48], we have selected the following variables as inputs to the ANN models to estimate daily streamflow: daily precipitation (P_t), daily temperature (T_t), precipitation of the previous n days (P_{t-n}), total rainfall of the preceding n days (R_n) and mean temperature over the previous n days ($T_{m,n}$). In this study, the most suitable delays of climate variables were determined using cross-correlation analyses, so we determined the temporal relationships between these input variables and streamflow. As shown in Figure 2a, the streamflow is highly positively correlated with

daily precipitation of the current day (P_t) and with daily precipitation of the previous days, until $t-4$ for LRB and until $t-2$ in HSRB.

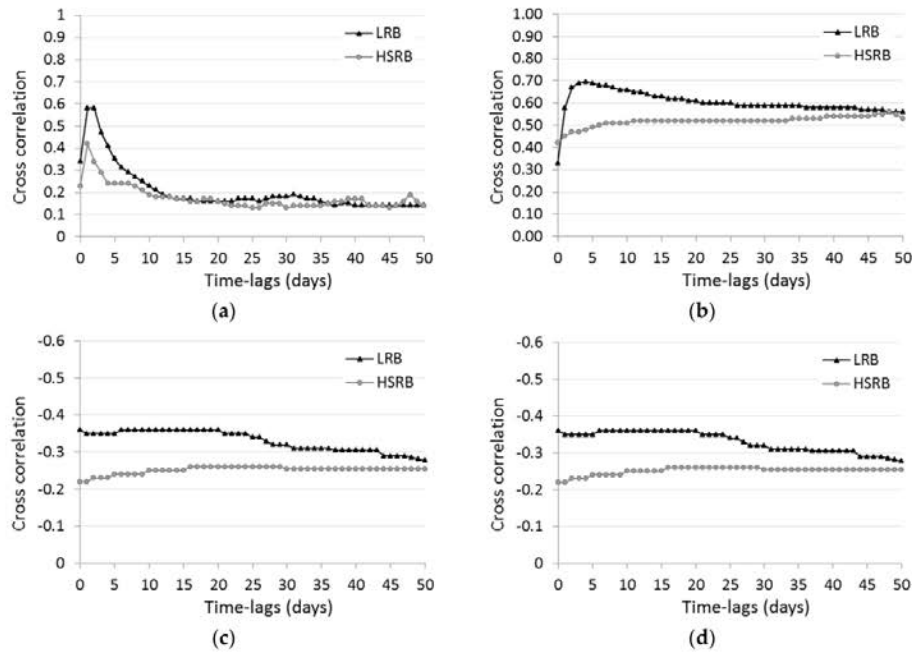


Figure 2. Cross-correlation analyses for LRB and HSRB between daily streamflow and (a) daily precipitation; (b) total rainfall of the preceding n days; (c) daily temperature; (d) mean temperature over the previous n days.

Streamflow is strongly correlated with accumulated daily rainfall; there is a greater correlation for 4 days in LRB and for 48 days in HSRB, reflecting the little and the great importance of groundwater, respectively, in these basins. With respect to the daily temperature, there are moderate negative correlations with the daily streamflow in both basins. Finally, a total of four input combinations have been proposed for each basin in this study (Table 7).

Table 7. Estimation scenarios for each basin.

Basin	Prediction Scenario	Input Combinations	Output
LRB	1	$P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, T_t$	Q_t
	2	P_t, R_4, T_t, Tm_{30}	Q_t
	3	$P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, R_4, T_t$	Q_t
	4	$P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, R_4$	Q_t
HSRB	1	$P_t, P_{t-1}, P_{t-2}, T_t$	Q_t
	2	$P_t, P_{t-1}, R_{48}, T_t$	Q_t
	3	P_t, P_{t-1}, R_{48}	Q_t
	4	P_{t-1}, R_{48}, Tm_{30}	Q_t

For the network structure identification, we implemented and built the ANNs using MATLAB® software (version 8.2.0.701 (R2013b), The Mathworks, Natick, MA, USA). A multilayer feed-forward

network was used. The number of hidden layers and hidden neurons was established by trial-and-error procedure; one or two hidden layers with a number of neurons between two and ten are considered. The number of neurons in the input layer depends on the number of input variables in each scenario, which varies from 3 to 7. Figure 3 shows the ANN structure used in this work.




Figure 3. Structure of multilayer feed-forward network used in this research.

The different scenarios defined in Table 7 were tested for determining the type and number of inputs to ANN models. Table 8 shows the best architecture of ANN and their performances for each scenario trained and validated for the studied basins. These performance measures values are averages obtained over the five rounds of cross-validation.

Table 8. Best network architectures and their average performance measures obtained in cross-validation for each prediction scenario.

Basin	Prediction Scenario	ANN Architecture (I-H-O) ¹	Training			Validation		
			NSE	PBIAS (%)	RMSE	NSE	PBIAS (%)	RMSE
LRB	1	6-2-1	0.63	1.17	22.51	0.59	12.52	23.02
	2	4-2-1	0.52	0.62	24.75	0.52	1.67	24.85
	3	7-2-1	0.62	2.91	22.64	0.58	12.07	23.52
	4	5-2-1	0.56	0.71	24.45	0.53	7.26	24.65
HSRB	1	4-2-1	0.28	5.52	1.96	-0.15	29.85	1.90
	2	4-4-1	0.55	2.16	1.54	0.26	13.53	1.66
	3	3-4-1	0.56	6.85	1.51	0.32	12.02	1.57
	4	3-3-3-1	0.47	1.29	1.69	0.10	21.15	1.81

¹ I is the number of neurons in input layer; H is the number of neurons in hidden layer (one or two hidden layers); O is the number of neurons in output layer.

The results shown in Table 8 indicate four effective ANN structures with good performances for LRB. Scenario 1 for LRB with a combination of six cells in the input layer (the precipitation of days t , $t-1$, $t-2$, $t-3$ and $t-4$, and the temperature of day t), one hidden layer with two neurons and one neuron in the output layer (the streamflow of day t) had the highest NSE and the lowest RMSE in the training and validation phase. Based on the criteria of Table 3, NSE and PBIAS of scenario 1 were good and very good, respectively. Therefore, scenario 1 was the selected architecture for LRB. However, the performance levels of ANN models for HSRB were lower in general because modelling the hydrological response of arid and semi-arid regions, where evapotranspiration rates are high and precipitation is irregular and/or limited, is especially complex [61]. The selected model for HSRB was scenario 3 where NSE and RMSE were better than those obtained in other proposed scenarios. In this scenario, NSE was classified as satisfactory and PBIAS as very good. The rest of the scenarios were classified as unsatisfactory based on NSE. Therefore, the ANN configuration selected for HSRB was three cells in the input layer (the precipitation of days t and $t-1$, and total rainfall of the preceding 48 days), one hidden layer with four neurons and one neuron in the output layer (the streamflow of day t). In conclusion, the structure selected for both basins was formed by three layers, similar to other studies (e.g., [1,23]).

3.3. Comparison of Model Performance

Calibration of SWAT models and training of the selected ANNs (scenario 1 for LRB and scenario 3 for HSRB) were done using the training data sets (1971–1989 for LRB and 1987–1997 for HSRB). Then, we tested the models with the validation sets (1990–2007 for LRB and 1998–2007 for HSRB). A comparison of flow estimation performance of the SWAT and ANN for LRB and HSRB is provided in Table 9, which shows separately the performances for the calibration/training and validation periods.

Table 9. Performances of SWAT and ANN models.

Basin	Model	Calibration/Training				Validation			
		NSE	PBIAS (%)	RMSE	R ²	NSE	PBIAS (%)	RMSE	R ²
LRB	SWAT	0.59	2.55	22.11	0.59	0.57	7.18	25.78	0.58
	ANN	0.64	2.03	20.81	0.63	0.59	12.94	25.39	0.61
HSRB	SWAT	0.52	4.37	1.76	0.53	0.48	8.74	1.45	0.49
	ANN	0.54	9.03	1.73	0.57	0.49	5.28	1.51	0.52

The values of NSE for both models were classified as good according to the criteria listed in Table 3 for the calibration/training phase in LRB and HSRB. For the validation phase, the NSE values ranged between 0.5 and 0.7, and therefore, they were classified as good for both models of the LRB. The NSE values were classified as satisfactory for both models of the HSRB. The PBIAS values were less than 25%, so they were classified as very good in all cases. The values of RMSE for both models were similar. The NSE and R² values obtained by the ANN model were higher than those obtained in SWAT in both basins, and those during training were higher than those during validation phases. After analysing these results, it was concluded that both SWAT and ANN were suitable. The more arid the catchment, the lower the performances obtained in the hydrological models, which is similar to the experience reported by Pérez-Sánchez et al., (2017) [61].

For a better understanding of the difference between the models, Figure 4 shows the results of SWAT and ANN models plotted against the observed values of streamflow for the calibration/training and validation periods with their correlation coefficients.

SWAT models had a poor performance in estimating the large values of streamflow, whereas ANN models were worse in estimating the small values. In every figure of Figure 4, the points which are related to streamflow with large values are positioned at a greater distance to the 1:1 line when the values have been estimated by SWAT. In contrast, the points related to the estimated streamflow by ANN models are farther from the 1:1 line when it comes to the estimation of small values.

The hydrographs (Figure 5) show the fit obtained for simulated versus measured streamflow in the studied basins during the validation period (from 1995 to 1997 for the LRB and from 2002 to 2004 for the HSRB). The models generally reproduce the streamflow fairly well. Although both models tended to underestimate the peak-flow events during the validation phase, ANN models were more sensitive to precipitation events than SWAT models, and their estimations always remain above those obtained by SWAT.

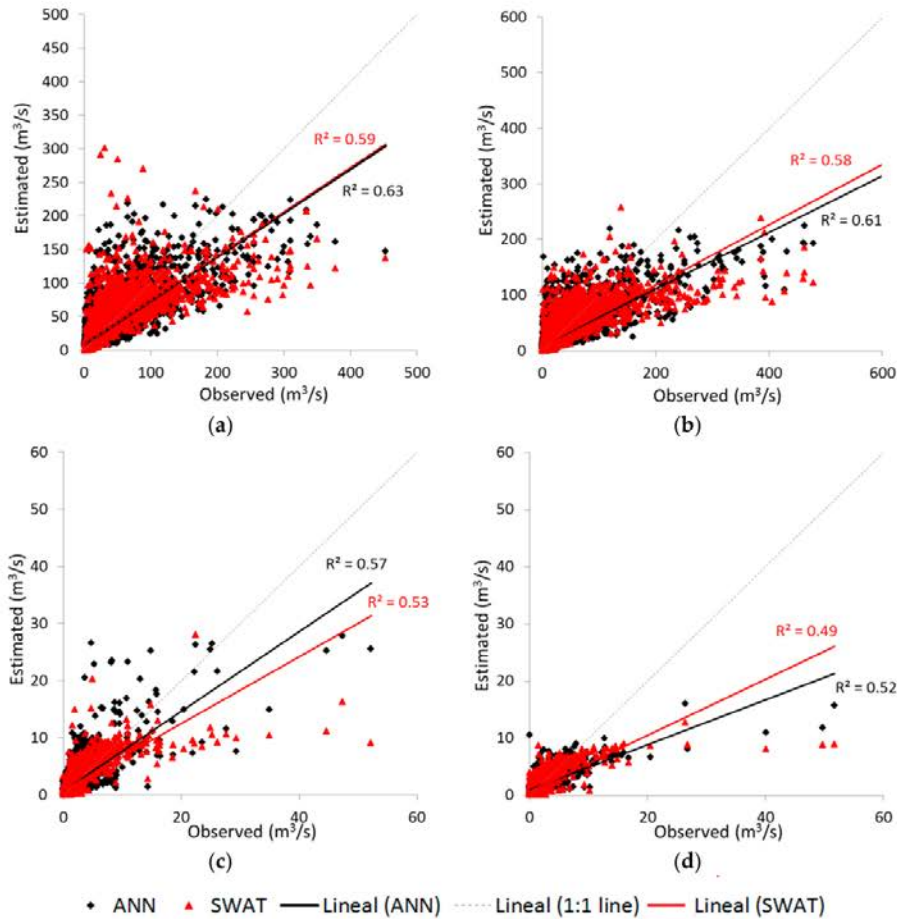


Figure 4. Scatterplots for daily streamflow obtained with SWAT and ANN in (a) calibration/training period of LRB; (b) validation period of LRB; (c) calibration/training period of HSRB; (d) validation period of HSRB.

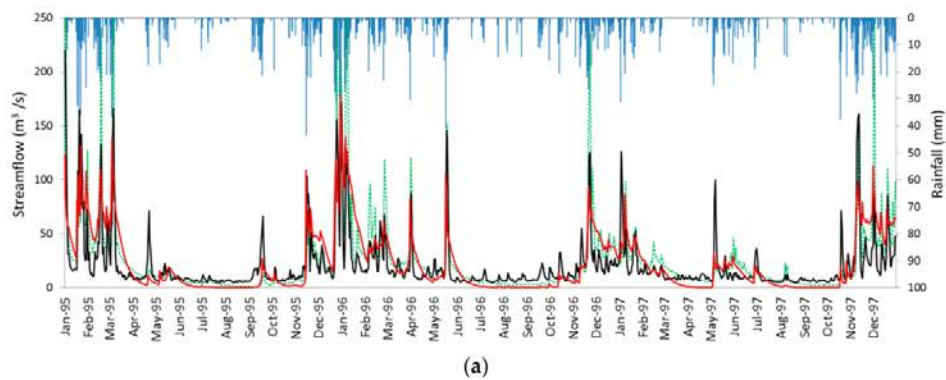


Figure 5. Cont.

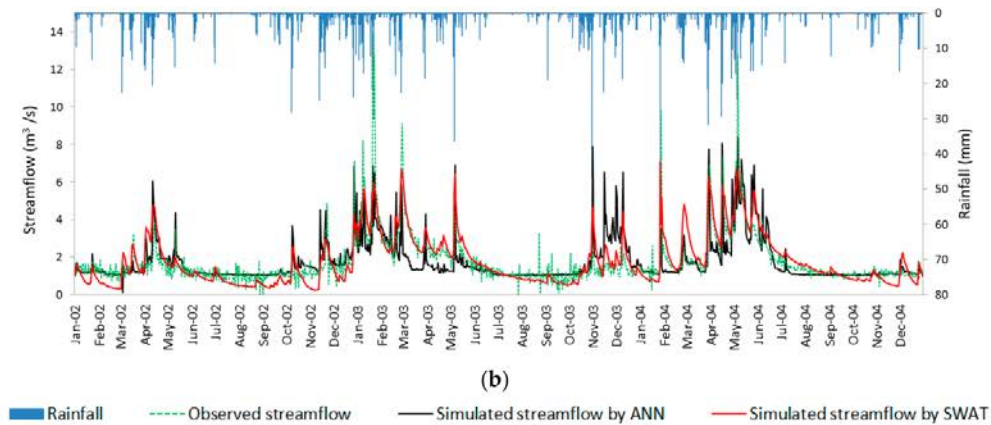


Figure 5. Comparison of observed and simulated daily streamflow by SWAT and ANN in validation phase, while the bar graph at the top is the daily precipitation for (a) LRB; (b) HSRB.

According to Chen and Chau (2016) [11], NSE and RMSE scale the mean squared error of estimation models, therefore they particularly reflect the performance on high values. Thus, the above discussions on evaluation criteria and plots of estimated data could not provide explicit performances on different intervals of values. To address this problem, different ranges of flow (from very high to very low flow) were determined. The reproduction of the streamflow was analysed by the FDC of LRB and HSRB for the validation periods (Figure 6). The FDC for LRB shows that the ANN performed generally better in the very high flow segment and SWAT was better in the very low flow segment. The values obtained by SWAT and by ANN were graphically similar for the rest of the flow segments in LRB. For HSRB, SWAT was better only in the very low flows.




Figure 6. FDC of validation period of (a) LRB; (b) HSRB.

An analysis of performance based on RMSE in each hydrograph phase was also done, as reflected in Table 10. The best results for each basin are highlighted in bold. As it was expected, high peaks are better simulated at the expense of low flows due to the fact that RMSE is biased towards high values. The RMSE values suggest that the SWAT model was better in the estimation of very low flows and ANN in the estimation of very high flows in all cases.

Table 10. RMSE values (m^3/s) of SWAT and ANN models in each hydrograph phase.

Hydrograph Phase	Basin									
	Range of Flow (m^3/s)	LRB				Range of Flow (m^3/s)	HSRB			
		Calibration		Validation			Calibration		Validation	
		SWAT	ANN	SWAT	ANN		SWAT	ANN	SWAT	ANN
Very high flow	[82.88, 478.29]	73.40	64.26	100.42	92.72	[4.52, 51.70]	6.64	5.80	5.98	5.81
High flow	[30.37, 82.87]	26.71	26.06	21.85	26.43	[2.14, 4.51]	1.53	2.29	0.91	1.30
Medium flow	[6.29, 30.32]	13.93	13.74	12.36	12.74	[1.03, 2.13]	0.99	0.84	0.73	0.64
Low flow	[1.21, 6.28]	5.17	8.97	6.79	10.10	[0.61, 1.02]	0.54	0.58	0.53	0.48
Very low flow	[0.48, 1.20]	1.50	7.80	1.00	7.41	[0, 0.60]	0.29	0.90	0.60	1.22

Similar results regarding peak-flow inefficiency of SWAT have been obtained in other studies (e.g., [5,22,23]), which suggested that peak-flow inefficiency could be caused by the formulation. The results obtained show that use of ANN models can help reduce the error in the estimation of high streamflow values, although these were also underestimated. One of the reasons is that the data of high values are scarce in the training data sets, the medium and low values being more numerous as illustrated in the cloud of points in the scatterplots in Figure 4. This problem in the application of neural network has also been reported in the works of Minns and Hall (1996) [15] and Talebizadeh et al., (2010) [62]. On the other hand, SWAT models simulated the estimation of the low flow values better than ANNs. In general, ANN models tended to overestimate the low values of streamflow. This inability can be attributed to complex non-linear relationships governing the process of low flow, often related to the base flow from groundwater. The performance of the ANN could be deteriorated with the increase in non-linearity [15]. It is generally accepted that the processes of streamflow generation are likely to be quite different during low, medium, and high flow periods. The base flow mainly contributes to low flow events whereas intense storm rainfall gives rise to high flow events [63]. Therefore, a single global ANN model could not predict the high and low runoff events satisfactorily [15]. SWAT models may obtain satisfactory results for the estimation of low flows but could not simulate very high streamflow with the same accuracy. In contrast to SWAT, a single ANN can obtain better results for very high values but not for the lowest values; these results are similar to those obtained by Kim et al., (2015) [23]. Therefore, the use of these models is suitable for simulating the streamflow in a basin. In the case of studies of extreme hydrologic events (e.g., floods), it is recommended to use an ANN model to simulate high-flow events. Otherwise, in studies of hydrological management in which low-flow events are more interesting, applying the SWAT model would be more desirable. In addition, it is important to take into account the disadvantages of each model. In Spain, it is relatively easier to obtain the input data, such as the streamflow and precipitation data, for the ANN model through the governmental online resources compared to data regarding the physical characteristics of river basins, such as soil moisture, infiltration, soil classes, groundwater level and evaporation, for the SWAT model. In addition, the time consumed in the setup and calibration of SWAT is higher than that consumed in the implementation of an ANN model. However, an ANN is a black box, and the water balance and its components are not obtained. The use of precipitation and temperature as the only inputs of the models is, on the other hand, a limitation of the ANN models used because the rainfall-runoff relation is impacted by different physical parameters too. The non-consideration of land use or land management in the ANN model makes the SWAT model more advantageous if a number of scenarios are to be made to investigate the response of the basin [1].

The results of this study suggest, however, that the ANN approach is very efficient to simulate a hydrological process because it requires very few input variables and minimal resources to implement and therefore, it is sufficiently promising to the development of other approaches such as the simulation of water quality process, as it is reflected in some studies (e.g., [64–66]).

4. Conclusions

We proposed the use of SWAT, a semi-physically based model, and ANN, a machine learning technique, to simulate the daily streamflow values and compare the results of both models in order to analyse their capabilities. They were applied in two basins with contrasting climates to check the validity of these models in basins with different climatic conditions. For determining the type and number of inputs for ANN models, four scenarios were considered in each studied basin, and they showed that the inclusion of daily precipitation, precipitation of previous days and total rainfall in the previous days was important to estimate the daily streamflow. After calibrating SWAT models for daily observed streamflow through the SUFI-2 algorithm, results indicated that SWAT has a better performance in estimating very low values of streamflow, whereas ANN estimated very high values with greater precision in all cases studied. Moreover, the results suggest that SWAT and ANN models were better when the climate was more humid. When the basin has more arid weather and, therefore, it is more complicated to model, ANN obtained better performance in more hydrograph phases. One of the advantages of the ANN model is that it does not require any physical characteristics of the watershed and, therefore, its implementation is easier. Nevertheless, in reverse, the totally implicit and physically meaningless features are also the major criticisms. It is still necessary to develop estimation models with conceptual ideas to reflect the characteristics of streamflow. ANN is a black box, and to gain knowledge about the water balance and its components, the SWAT model is more useful. Despite the advantages and disadvantages of each model, the results suggest that to simulate values of streamflow time-series, the choice between the SWAT or ANN has an impact on the accuracy of estimated flow. This idea for modelling streamflow can be extended to other machine learning techniques, which we could explore in future works. In addition, the ANN model only considers the inputs of precipitation and temperature. The influences of other inputs related to the streamflow can be explored additionally to improve the current study.

Acknowledgments: The first author was supported by the Catholic University of Murcia (UCAM) research scholarship program. This work has been partially supported by GESINHIMPADAPT project (CGL2013-48424-C2-2-R). We acknowledge Papercheck Proofreading & Editing Services.

Author Contributions: All authors contributed significantly to the development of the methodology applied in this study. Patricia Jimeno-Sáez designed the experiments and wrote the manuscript. Julio Pérez-Sánchez and Javier Senent-Aparicio helped to perform the experiments and reviewed and helped to prepare this paper for publication. David Pulido-Velázquez as the supervisor of Patricia Jimeno-Sáez provided many important advices on the concept of methodology and structure of the manuscript.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Amirhossien, F.; Alireza, F.; Kazem, J.; Mohammadbagher, S. A comparison of ANN and HSPF models for runoff simulation in Balkhichai river watershed, Iran. *Am. J. Clim. Chang.* **2015**, *4*, 203–216. [[CrossRef](#)]
2. Pfannerstill, M.; Björn, G.; Föhrer, N. Smart Low Flow Signature Metrics for an Improved Overall Performance Evaluation of Hydrological Models. *J. Hydrol.* **2014**, *510*, 447–458. [[CrossRef](#)]
3. Madsen, H. Automatic calibration of a conceptual rainfall–runoff model using multiple objectives. *J. Hydrol.* **2000**, *235*, 276–288. [[CrossRef](#)]
4. Noori, N.; Kalin, L. Coupling SWAT and ANN models for enhanced daily stream flow Prediction. *J. Hydrol.* **2016**, *533*, 141–151. [[CrossRef](#)]
5. Makwana, J.J.; Tiwari, M.K. Hydrological stream flow modelling using soil and water assessment tool (SWAT) and neural networks (NNs) for the Limkheda watershed, Gujarat, India. *Model. Earth Syst. Environ.* **2017**, *3*, 635–645. [[CrossRef](#)]
6. Arnold, J.G.; Srinivasan, R.; Muttiah, R.S.; Williams, J.R. Large area hydrologic modeling and assessment part I: Model development. *J. Am. Water Resour. Assoc.* **1998**, *34*, 73–89. [[CrossRef](#)]
7. Grusson, Y.; Antcil, F.; Sauvage, S.; Sánchez Pérez, J.M. Testing the SWAT Model with Gridded Weather Data of Different Spatial Resolutions. *Water* **2017**, *9*, 54. [[CrossRef](#)]

8. Abbaspour, K.C.; Rouholahnejad, E.; Vaghefi, S.; Srinivasan, R.; Yang, H.; Klove, B. A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *J. Hydrol.* **2015**, *524*, 733–752. [[CrossRef](#)]
9. Olyaei, E.; Banejad, H.; Chau, K.W.; Melesse, A.M. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: A case study in United States. *Environ. Monit. Assess.* **2015**, *187*, 189. [[CrossRef](#)] [[PubMed](#)]
10. Gholami, V.; Chau, K.W.; Fadaee, F.; Torkaman, J.; Ghaffari, A. Modeling of groundwater level fluctuations using dendrochronology in alluvial aquifers. *J. Hydrol.* **2015**, *529*, 1060–1069. [[CrossRef](#)]
11. Chen, X.Y.; Chau, K.W. A hybrid double feedforward neural network for suspended sediment load estimation. *Water Resour. Manag.* **2016**, *30*, 2179–2194. [[CrossRef](#)]
12. Jimeno-Sáez, P.; Senent-Aparicio, J.; Pérez-Sánchez, J.; Pulido-Velazquez, D.; Cecilia, J.M. Estimation of Instantaneous Peak Flow Using Machine-Learning Models and Empirical Formula in Peninsular Spain. *Water* **2017**, *9*, 347. [[CrossRef](#)]
13. Panu, U.S.; Khalil, M.; Elshorbagy, A. Streamflow data infilling techniques based on concepts of groups and neural networks. In *Artificial Neural Networks in Hydrology*; Govindaraju, R.S., Rao, A.R., Eds.; Water Science and Technology Library; Springer: Dordrecht, The Netherlands, 2000; Volume 36, pp. 235–258. ISBN 978-94-015-9341-0. [[CrossRef](#)]
14. Elsholberg, A.; Simonovic, S.P.; Panu, U.S. Estimation of missing streamflow data using principles of chaos theory. *J. Hydrol.* **2002**, *255*, 123–133. [[CrossRef](#)]
15. Minns, W.; Hall, M.J. Artificial neural networks as rainfall-runoff models. *Hydrol. Sci. J.* **1996**, *41*, 399–417. [[CrossRef](#)]
16. Talebizadeh, M.; Moridnejad, A. Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models. *Exp. Syst. Appl.* **2011**, *38*, 4126–4135. [[CrossRef](#)]
17. Singh, A.; Imtiyaz, M.; Isaac, R.K.; Denis, D.M. Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. *Agric. Water Manag.* **2012**, *104*, 113–120. [[CrossRef](#)]
18. Shiau, J.T.; Hsu, H.T. Suitability of ANN-based daily streamflow extension models: a case study of Gaoping River basin, Taiwan. *Water Resour. Manag.* **2016**, *30*, 1499–1513. [[CrossRef](#)]
19. Ng, W.W.; Panu, U.S.; Lennox, W.C. Comparative studies in problems of missing extreme daily streamflow records. *J. Hydrol. Eng.* **2009**, *14*, 91–100. [[CrossRef](#)]
20. Wang, Y.; Guo, S.; Xiong, L.; Liu, P.; Liu, D. Daily Runoff Forecasting Model Based on ANN and Data Preprocessing Techniques. *Water* **2015**, *7*, 4144–4160. [[CrossRef](#)]
21. Srivastava, P.; McNair, J.N.; Johnson, T.E. Comparison of process-based and artificial neural network approaches for streamflow modeling in an agricultural watershed. *J. Am. Water Resour. Assoc.* **2006**, *42*, 545–563. [[CrossRef](#)]
22. Demirel, M.C.; Venancio, A.; Kahya, E. Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Adv. Eng. Softw.* **2009**, *40*, 467–473. [[CrossRef](#)]
23. Kim, M.; Baek, S.; Ligaray, M.; Pyo, J.; Park, M.; Cho, K.H. Comparative studies of different imputation methods for recovering streamflow observation. *Water* **2015**, *7*, 6847–6860. [[CrossRef](#)]
24. Coch, A.; Mediero, L. Trends in low flows in Spain in the period 1949–2009. *Hydrol. Sci. J.* **2016**, *61*, 568–584. [[CrossRef](#)]
25. Instituto Geológico y Minero de España (IGME). Identificación y Caracterización de la Interrelación Que Se Presenta Entre Aguas Subterráneas, Cursos Fluviales, Descargas Por Manantiales, Zonas Húmedas y Otros Ecosistemas Naturales de Especial Interés Hídrico: 011 Miño-Sil. Memoria Técnica (In Spanish). Available online: http://info.igme.es/SidPDF/146000/839/146839_0000001.pdf (accessed on 7 September 2017).
26. Senent-Aparicio, J.; Pérez-Sánchez, J.; Carrillo-García, J.; Soto, J. Using SWAT and Fuzzy TOPSIS to Assess the Impact of Climate Change in the Headwaters of the Segura River Basin (SE Spain). *Water* **2017**, *9*, 149. [[CrossRef](#)]
27. Moral, F.; Cruz-Sanjulian, J.J.; Olias, M. Geochemical evolution of groundwater in the carbonate aquifers of Sierra de Segura (Betic Cordillera, southern Spain). *J. Hydrol.* **2008**, *360*, 281–296. [[CrossRef](#)]
28. Belmar, O.; Velasco, J.; Martinez-Capel, F. Hydrological classification of natural flow regimes to support environmental flow assessments in intensively regulated Mediterranean rivers, Segura River Basin (Spain). *Environ. Manag.* **2011**, *47*, 992. [[CrossRef](#)] [[PubMed](#)]

29. Centre for Public Works Studies and Experimentation (CEDEX). Anuario de Aforos (In Spanish). Available online: <http://ceh-flumen64.cedex.es/anuarioaforos/default.asp> (accessed on 20 August 2017).
30. Confederation of the Segura River. Visor GIS Para Consulta y Descarga de Datos de Embalses. Available online: <https://www.chsegura.es/chs/cuenca/redesdecontrol/estadisticashidrologicas/visorembalses/visorjs.html> (accessed on 20 August 2017).
31. Herrera, S.; Gutiérrez, J.M.; Ancell, R.; Pons, M.R.; Frías, M.D.; Fernández, J. Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over Spain (Spain02). *Int. J. Climatol.* **2012**, *32*, 74–85. [CrossRef]
32. Ciach, G.J. Local random errors in tipping-bucket rain gauge measurements. *J. Atmos. Ocean. Technol.* **2010**, *20*, 752–759. [CrossRef]
33. National Geographic Institute of Spain. Available online: <http://www.ign.es/web/ign/portal> (accessed on 17 August 2017).
34. Nachtergaele, F.; van Velthuizen, H.; Verelst, L.; Batjes, N.; Dijkshoorn, K.; van Engelen, V.; Fischer, G.; Jones, A.; Montanarella, L.; Petri, M. *Harmonized World Soil Database*; Food and Agriculture Organization of the United Nations: Rome, Italy, 2008.
35. Corine Land Cover 2006. Seamless Vector Data—European Environment Agency. Available online: <https://www.eea.europa.eu/data-and-maps/data/clc-2006-vector-4> (accessed on 20 June 2017).
36. Hargreaves, G.H. Defining and using reference evapotranspiration. *J. Irrig. Drain. Eng.* **1994**, *120*, 1132–1139. [CrossRef]
37. Schneider, K.; Ketzner, B.; Breuer, L.; Vaché, K.B.; Bernhofer, C.; Frede, H.G. Evaluation of evapotranspiration methods for model validation in a semi-arid watershed in northern China. *Adv. Geosci.* **2007**, *11*, 37–42. [CrossRef]
38. Singh, V.; Bankar, N.; Salunkhe, S.S.; Bera, A.K.; Sharma, J.R. Hydrological stream flow modelling on Tungabhadra catchment: parameterization and uncertainty analysis using SWAT CUP. *Curr. Sci. India* **2013**, *104*, 1187–1199.
39. Abbaspour, K.C.; Vajdani, M.; Haghghat, S. SWAT-CUP calibration and uncertainty programs for SWAT. In Proceedings of the Modsim 2007: International Congress on Modelling and Simulation, Christchurch, New Zealand, 3–8 December 2007; pp. 1603–1609.
40. Arnold, J.G.; Moriasi, D.N.; Gassman, P.W.; Abbaspour, K.C.; White, M.J.; Srinivasan, R.; Santhi, C.; Harmel, R.D.; van Griensven, A.; van Liew, M.W.; et al. SWAT: Model use, calibration, and validation. *Trans. ASABE* **2012**, *55*, 1491–1508. [CrossRef]
41. Molina-Navarro, E.; Martínez-Pérez, S.; Sastre-Merlín, A.; Bienes-Allas, R. Hydrologic modeling in a small mediterranean basin as a tool to assess the feasibility of a limno-reservoir. *J. Environ. Qual.* **2014**, *43*, 121–131. [CrossRef] [PubMed]
42. Yang, J.; Reichert, P.; Abbaspour, K.C.; Xia, J.; Yang, H. Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. *J. Hydrol.* **2008**, *358*, 1–23. [CrossRef]
43. Govindaraju, R.S. Artificial neural networks in hydrology. I: Preliminary concepts. *J. Hydrol. Eng.* **2000**, *5*, 115–123. [CrossRef]
44. Levenberg, K. A Method for the Solution of Certain Problems in Least Squares. *Appl. Math.* **1944**, *2*, 164–168.
45. Marquardt, D. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Appl. Math.* **1963**, 431–441. [CrossRef]
46. Nayebi, M.; Khalili, D.; Amin, S.; Zand-Parsa, S. Daily stream flow prediction capability of artificial neural networks as influenced by minimum air temperature data. *Biosyst. Eng.* **2006**, *95*, 557–567. [CrossRef]
47. Kişi, Ö. Streamflow forecasting using different artificial neural network algorithms. *J. Hydrol. Eng.* **2007**, *12*, 532–539. [CrossRef]
48. Yaseen, Z.M.; El-shafie, A.; Jaafar, O.; Afan, H.A.; Sayl, K.N. Artificial intelligence based models for stream-flow forecasting: 2000–2015. *J. Hydrol.* **2015**, *530*, 829–844. [CrossRef]
49. Elliott, D.L. *A Better Activation Function for Artificial Neural Networks*; Institute for Systems Research, University of Maryland: College Park, MD, USA, 1993.
50. Dawson, C.W.; Wilby, R.L. Hydrological modelling using artificial neural networks. *Prog. Phys. Geogr.* **2001**, *25*, 80–108. [CrossRef]
51. Moriasi, D.N.; Arnold, J.G.; Van Liew, M.W.; Bingner, R.L.; Harmel, R.D.; Veith, T.L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. Am. Soc. Agric. Eng.* **2007**, *50*, 885–900. [CrossRef]

52. Gupta, H.V.; Sorooshian, S.; Yapo, P.O. Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. *J. Hydrol. Eng.* **1999**, *4*, 135–143. [[CrossRef](#)]
53. Kalin, L.; Isik, S.; Schoonover, J.E.; Lockaby, B.G. Predicting water quality in unmonitored watersheds using Artificial Neural Networks. *J. Environ. Qual.* **2010**, *39*, 1429–1440. [[CrossRef](#)] [[PubMed](#)]
54. American Society of Agricultural and Biological Engineers (ASABE). *Guidelines for Calibrating, Validating, and Evaluating Hydrologic and Water Quality (H/WQ) Models*; ASABE 621 JUN2017; ASABE: St. Joseph, MI, USA, 2017.
55. Raposo, J.R.; Dafonte, J.; Molinero, J. Assessing the impact of future climate change on groundwater recharge in Galicia-Costa, Spain. *Hydrogeol. J.* **2013**, *21*, 459–479. [[CrossRef](#)]
56. Conan, C.; de Marsily, G.; Bouraoui, F.; Bidoglio, G. A long-term hydrological modeling of the upper Guadiana river basin (Spain). *Phys. Chem. Earth* **2003**, *28*, 193–200. [[CrossRef](#)]
57. Arnold, J.G.; Kiniry, J.R.; Srinivasan, R.; Williams, J.R.; Haney, E.B.; Neitsch, S.L. *Soil and Water Assessment Tool Input/Output Documentation: Version 2012*; Texas Water Resources Institute Technical Report: College Station, TX, USA, 2012; Volume TR-439, Available online: <http://swat.tamu.edu/media/69296/SWAT-IO-Documentation-2012.pdf> (accessed on 20 June 2017).
58. Neitsch, S.L.; Arnolds, J.G.; Kiniry, J.R.; Williams, J.R. *Soil and Water Assessment Tool Theoretical Documentation*, version 2009; Texas A&M University: College Station, TX, USA, 2011. Available online: <http://swat.tamu.edu/media/99192/swat2009-theory.pdf> (accessed on 2 July 2017).
59. Soriano, G.; Samper, J. Monitoring and modelling water quantity and quality in a pilot catchment in north-western Spain. In *Monitoring and Modelling Catchment Water Quantity and Quality*; Verhoest, N., Hudson, J., Hoeben, R., De Troch, F., Eds.; IHP-VI, Technical Documents in Hydrology, No. 66; UNESCO: Paris, France, 2003.
60. Arnold, J.G.; Allen, P.M. Automated methods for estimating baseflow and ground water recharge from streamflow records. *JAWRA* **1999**, *35*, 411–424. [[CrossRef](#)]
61. Pérez-Sánchez, J.; Senent-Aparicio, J.; Segura-Méndez, F.; Pulido-Velazquez, D. Assessment of lumped hydrological balance models in peninsular Spain. *Hydrol. Earth Syst. Sci.* **2017**. [[CrossRef](#)]
62. Talebizadeh, M.; Morid, S.; Ayyoubzadeh, S.A.; Ghasemzadeh, M. Uncertainty analysis in sediment load modeling using ANN and SWAT model. *Water Resour. Manag.* **2010**, *24*, 1747–1761. [[CrossRef](#)]
63. Wu, C.L.; Chau, K.W.; Li, Y.S. Predicting monthly streamflow using data-driven models coupled with data-preprocessing techniques. *Water Resour. Res.* **2009**, *45*. [[CrossRef](#)]
64. Babbar, R.; Babbar, S. Predicting river water quality index using data mining techniques. *Environ. Earth Sci.* **2017**, *76*, 504. [[CrossRef](#)]
65. Huo, S.; He, Z.; Su, J.; Xi, B.; Zhu, C. Using artificial neural network models for eutrophication prediction. *Procedia Environ. Sci.* **2013**, *18*, 310–316. [[CrossRef](#)]
66. Kuo, J.T.; Hsieh, M.H.; Lung, W.S.; She, N. Using artificial neural network for reservoir eutrophication prediction. *Ecol. Model.* **2007**, *200*, 171–177. [[CrossRef](#)]



4.2 PUBLICACIÓN 2: ESTIMATION OF INSTANTANEOUS PEAK FLOW USING MACHINE-LEARNING MODELS AND EMPIRICAL FORMULA IN PENINSULAR SPAIN

Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., Pulido-Velazquez, D., y Cecilia, J. M. (2017). Estimation of Instantaneous Peak Flow Using Machine-Learning Models and Empirical Formula in Peninsular Spain. *Water*, 9(5), 347.
<https://doi.org/10.3390/w9050347>



Article

Estimation of Instantaneous Peak Flow Using Machine-Learning Models and Empirical Formula in Peninsular Spain

Patricia Jimeno-Sáez ¹, Javier Senent-Aparicio ^{1,*}, Julio Pérez-Sánchez ¹,
David Pulido-Velázquez ^{1,2} and José María Cecilia ³

¹ Department of Civil Engineering, Catholic University of San Antonio, Campus de los Jerónimos s/n, Guadalupe, 30107 Murcia, Spain; pjimeno@ucam.edu (P.J.-S.); jperez058@ucam.edu (J.P.-S.); d.pulido@igme.com (D.P.-V.)

² Geological Survey of Spain (IGME), Granada Unit, Urb. Alcázar del Genil, 4, Edificio Zulema, 18006 Granada, Spain

³ Department of Computer Engineering, Catholic University of San Antonio, Campus de los Jerónimos s/n, Guadalupe, 30107 Murcia, Spain; jmcecilia@ucam.edu

* Correspondence: jsenent@ucam.edu; Tel.: +34-968-278-818

Academic Editor: Yunqing Xuan

Received: 1 April 2017; Accepted: 11 May 2017; Published: 15 May 2017

Abstract: The design of hydraulic structures and flood risk management is often based on instantaneous peak flow (IPF). However, available flow time series with high temporal resolution are scarce and of limited length. A correct estimation of the IPF is crucial to reducing the consequences derived from flash floods, especially in Mediterranean countries. In this study, empirical methods to estimate the IPF based on maximum mean daily flow (MMDF), artificial neural networks (ANN), and adaptive neuro-fuzzy inference system (ANFIS) have been compared. These methods have been applied in 14 different streamflow gauge stations covering the diversity of flashiness conditions found in Peninsular Spain. Root-mean-square error (RMSE), and coefficient of determination (R^2) have been used as evaluation criteria. The results show that: (1) the Fuller equation and its regionalization is more accurate and has lower error compared with other empirical methods; and (2) ANFIS has demonstrated a superior ability to estimate IPF compared to any empirical formula.

Keywords: artificial neural network; ANFIS; Peninsular Spain; instantaneous peak flow; hydraulic design

1. Introduction

Flash floods are one of the most significant natural hazards in Europe, especially in the Mediterranean countries [1]. In recent years, flash floods have caused many economic losses and loss of life throughout Peninsular Spain. As can be seen in Barredo (2007) [2], Spain is the country in Europe that has been the most affected by flash floods from 1950 to 2005. Estimation of the frequency and magnitude of the instantaneous peak flow (IPF) is crucial for the design of hydraulic structures and floodplain management [3]. As happens in many countries, Spanish basin management agencies record data relating to mean daily flow (MDF) while the availability of IPF time series is less frequent. The application of techniques that reduce uncertainties associated with IPF estimations is needed because of the damage that flash floods cause.

Several methods for estimating IPF based on MDF have been developed. From an empirical point of view, there are two types of approaches to estimating IPF based on MDF. The first type of approach establishes a relationship between IPF and MDF using the physiographic characteristics of the basin and the second type of approach calculates IPF using the sequence of mean daily flow. In the first

group, the method by Fuller (1914) [4] is included; he conducted one of the first studies related to obtaining the IPF from the maximum MDF (MMDF) using drainage area. Other studies, such as those by Silva (1997) [5] and Silva and Tucci (1998) [6], also used the physiographic characteristics to estimate the IPF. Taguas et al. (2008) [7] proposed an equation to estimate IPF from MMDF, drainage area and mean annual rainfall in Southeastern Spain. Among the methods that use the second approach, there are two pioneering methods [8,9] described by Linsley et al. (1949) [10] and the Sangal (1983) [11]. Many studies adjusted Fuller's formula for use in their regions. Fill and Steiner (2013) [12] summarized many of these regional formulas in their research. In Spain, the Spanish Centre for Public Works Studies and Experimentation CEDEX [13] adjusted the Fuller formula to obtain thirteen regional equations, which cover Peninsular Spain. In this research, four of these empirical methods were evaluated. Two of them, Fuller's (1914) [4] and the regionalized formula obtained by CEDEX, are included in the first approach group and Sangal (1983) [11] and the Fill and Steiner (2013) [12] methodologies are included in the second group.

According to recent studies [14], new methods have increased the accuracy associated with estimating IPF through the application of data-driven techniques, such as adaptive neuro-fuzzy inference systems (ANFIS) and artificial neural networks (ANN). Therefore, in this work, we have also employed the ANN and ANFIS, which are machine-learning methods used widely in order to compare the results obtained by applying the empirical formula. ANNs reproduce the learning process of the human brain [15]. An ANN is a powerful and efficient mathematical model for linear and nonlinear approximations and is often known as a universal approximator [16]. Mustafa et al. (2012) [17] examined the effectiveness of ANNs in solving different hydrologic problems and concluded that appropriate ANN modelling is advantageous compared with conventional modelling techniques. Generalizability and forecast accuracy are some advantages of ANNs [18]. These properties make ANNs suitable for solving problems of estimation and prediction in hydrology [19]. ANNs have the capability of obtaining the relationship between the predictor variables (in this case, MMDF) and the estimated variables (here, IPF) of a process [16,19]. We have also used the ANFIS model to estimate IPF from MMDF. ANFIS is another powerful technique for modeling a nonlinear system and it integrates fuzzy logic into neural networks. Therefore, ANFIS has the ANN learning ability [20]. The ANFIS model is a fusion of ANN and a Fuzzy Inference System (FIS) and possesses the advantages of both systems. The benefit of ANNs is that it learns independently and adapts itself to changing environments and the advantage of FIS is that it systematically generates unknown fuzzy rules from given information (inputs/outputs) [21]. Therefore, this combination allows a FIS to learn from the data to create models. This is an efficient model for determining the behaviour of imprecisely defined complex dynamical systems [22]. This model has also been accepted as an efficient alternative technique for modeling and prediction in hydrology [23]. Some researchers who have applied ANFIS in hydrological modelling are Dastorani et al. (2010) [24] and Seckin (2011) [25].

Although ANN and ANFIS have great advantages, there are also certain disadvantages [26,27], such as: (1) Neural networks are a black box and do not clarify the functional relationship between the input and output values; (2) a neural network has to be trained for each problem to obtain the adequate architecture, and this requires greater computational resources; and (3) ANFIS is more complicated than FIS and is not available for all FIS options.

Many hydrological studies have shown that ANFIS was more efficient than other models as recurrent neural networks or fuzzy logic [28,29]. Shabani et al. (2012) [30] and Dastorani et al. (2013) [31] applied ANFIS and ANNs to estimate IPF from MMDF and compared their results with the methods of Fuller [4], Sangal [11], and Fill-Steiner [12]. They found that ANFIS increased the accuracy of the estimation of the IPF. The aim of this study is to identify a method to estimate IPF with greater accuracy in fourteen watersheds covering the diversity of flashiness conditions found in Peninsular Spain. In those basins, longer MDF data series exist, but the IPF data series are shorter. Nevertheless, at least 30 years of IPF data are available in the selected basins in order to compare the performance between estimated and measured IPF.

2. Materials and Methods

2.1. Study Area and Data

Spain shows a wide range of climatic characteristics due to its position between the European temperature zone and the subtropical zone. It also includes some of the rainiest areas in Europe in the northeast as well as the driest ones in the southeast, with a marked long drought period in summer. A set of 14 flow gauging stations distributed over peninsular Spain was selected to serve as a case study. The basins were selected based on several criteria. It was intended to have (1) a wide diversity of various flow regimes representative of the diversity of the conditions across Peninsular Spain; (2) a sufficiently long time series (more than 30 years) from gauging stations located in near-natural basins; (3) basin areas not exceeding 1000 km². As shown in Figure 1, the basins used in this study are well distributed over Peninsular Spain, covering the three main climatic zones distinguished in Peninsular Spain: the Mediterranean climate, which is characterised by dry and warm summers and cool to mild, wet winters; the oceanic climate, which is located in the northern part of the country; and the semiarid climate, which is present in the centre and southeastern parts of the country, where in contrast to the Mediterranean climate, the dry season continues beyond the end of summer.

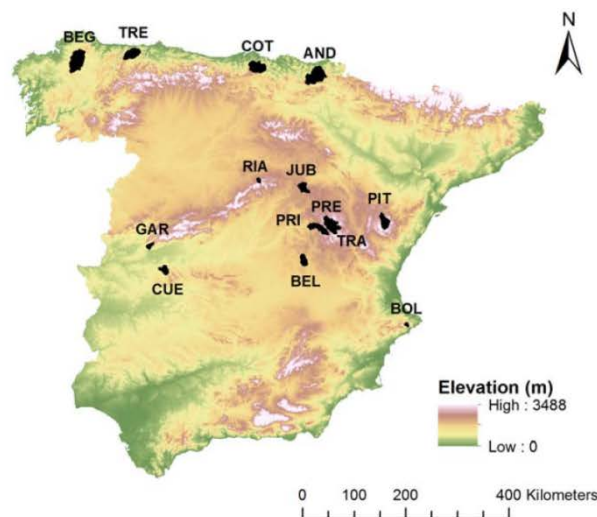


Figure 1. Location of the selected basins.

Table 1 lists the set of 14 basins, showing basin areas ranging from 29 to 837 km² with an average area of 307 km², altitudes vary from 16 to 1278 m and streamflow data covering a period ranging from 38 to 70 years. According to the Koppen climate classification system [32], among the fourteen studied basins, six of them are considered warm-summer Mediterranean climates (Csb), four of them are considered oceanic climates (Cfb), three of them are considered hot-summer Mediterranean climates (Csa), and there is only one basin representing semi-arid climate (Bsk). There is no south-western basin in this study due to the lack of data in this area, which has been studied for less than ten years in most gauging stations. Besides, according to Senent-Aparicio et al. (2016) [33], Southern Spain is one of the most water-stressed regions of Europe, and this is why it is very difficult to find near-natural basins in this part of Spain. In order to evaluate the flashiness of the basins selected, the Richards-Baker Flashiness Index (R-B Index) [34] has been obtained. This index reflects the velocity and frequency of short term changes in streamflow in response to storm events and can be calculated as shown in Equation (1).

$$R - B_{Index} = \frac{\sum_{i=1}^n |q_{i-1} - q_i|}{\sum_{i=1}^n q_i} \quad (1)$$

where, i is the time step, n is the total number of time step and q is the daily flow.

As shown in Table 1, the R-B Index in the basins selected range from 0.08 to 0.47, covering the diversity of flashiness conditions found in Peninsular Spain. Higher values for this index indicate higher flashiness (flashy streams), whereas lower values indicate stable streams. Climates, topography, geology, percentages of forest cover, catchment area and shape, land use and other catchment attributes influence the streamflow regime and, hence, the flashiness index [34]. Depending on the case study, different correlations between flashiness index and catchment attributes can be found. We have found a negative correlation with the mean catchment elevation, and this is similar to results obtained by Holko et al. (2011) [35]. The daily flow data and streamflow gauging stations were collected from the CEDEX [36].

Table 1. Summary of the main characteristics of the selected basins.

Name	Code	Area (km ²)	Altitude (m)	R-B Index	Köppen Classification	Flow Availability (Years)
Trevias	TRE	411	35	0.24	Cfb	43
Begonte	BEG	843	395	0.24	Csb	43
Coterillo	COT	485	16	0.47	Cfb	40
Andoain	AND	765	38	0.39	Cfb	43
Priego	PRI	345	818	0.12	Csb	46
Bolulla	BOL	30	120	0.17	Bsk	38
Gargüera	GAR	97	380	0.29	Csa	40
Cuernacabras	CUE	120	305	0.31	Csa	40
Jubera	JUB	196	892	0.10	Csb	62
Tramacastilla	TRA	95	1278	0.10	Csb	48
Belmontejo	BEL	187	830	0.08	Csa	42
Peralejo de las Truchas	PER	410	1143	0.16	Csb	68
Riaza	RIA	36	1139	0.16	Csb	70
Pitarque	PIT	279	990	0.09	Cfb	45

2.2. Empirical Formulas

The only way to obtain instantaneous flows accurately is to measure them. If these have not been measured, any attempt to obtain the instantaneous flow afterwards will result in an approximate value. Although the relationship between MDF and IPF is logically variable from one flood to another, in most watersheds, this relationship is usually more or less constant or, at least, it fluctuates within a relatively narrow range of values [13]. This has led to the application of empirical formulas to calculate the unknown values of IPF from the known values of MDF. The following are the different empirical methods used in this study.

2.2.1. Fuller

Fuller [4] studied flood data of 24 watersheds in The United States with basin areas between 3.06 and 151,592 km² and suggested an equation where IPF is calculated from MMDF as a function of the drainage area. Fuller formula (Equation (2)) is the most important and widely accepted due to its simplicity [11].

$$IPF = MMDF \times (1 + 2.66 \times A^{-0.3}) \quad (2)$$

where IPF is the estimated instantaneous peak flow (m³/s), MMDF is the maximum observed mean daily flow (m³/s), and A is the drainage area (km²). The coefficients present in Equation (2) are regression coefficients that were obtained in Fuller's study [4].

2.2.2. CEDEX Regionalization of Fuller's Formula

In 2011, CEDEX [13] published a technical report about methodologies used in maximum streamflow mapping of the different river basin districts of Spain. CEDEX proposed twelve regional

formulas to transform MMDF data into the corresponding IPF based on Fuller’s method. Each formula corresponds to a river basin district; these are shown in Table 2. In these regional formulas, IPF is the estimated instantaneous peak flow (m³/s), MMDF is the maximum observed mean daily flow (m³/s), A is the drainage area (km²) and the coefficients have been obtained by regression for each region.

2.2.3. Sangal

In his study, Sangal [11] realised several calculations based on a triangular hydrograph and proposed the following formula (Equation (3)) where the variables are the mean daily flow of three consecutive days.

$$IPF = \frac{4 \times MMDF - Q1 - Q3}{2} \tag{3}$$

where IPF is the estimated instantaneous peak flow (m³/s), MMDF is the maximum observed mean daily flow (m³/s), Q1 is the mean daily flow on the preceding day (m³/s), and Q3 is the mean daily flow on the following day.

Sangal tested his method using data from 387 gauging stations in Ontario (Canada) for basin areas measuring less than 1 km² to more than 100,000 km². He obtained good estimations in the majority of basins, although in small basins the peak flow could be underestimated.

Table 2. Regional formulas of CEDEX [13].

River Basin District	Formula
Miño-Sil and Galicia Costa	IPF = MMDF × (1 + 1.81 × A ^{-0.23})
Cantábrico and País Vasco	IPF = MMDF × (1 + 3.1 × A ^{-0.26})
Duero	IPF = MMDF × (1 + 1.78 × A ^{-0.29})
Tajo	IPF = MMDF × (1 + 5.01 × A ^{-0.38})
Guadiana and Guadalquivir (Zone 1)	IPF = MMDF × (1 + 35.89 × A ^{-0.72})
Guadiana and Guadalquivir (Zone 2)	IPF = MMDF × (1 + 112.82 × A ^{-0.7})
Guadiana and Guadalquivir (Zone 3)	IPF = MMDF × (1 + 11.56 × A ^{-0.42})
Jucar	IPF = MMDF × (1 + 20.87 × A ^{-0.51})
Segura	IPF = MMDF × (1 + 145.85 × A ^{-0.75})
Ebro (Zone 1)	IPF = MMDF × (1 + 2.49 × A ^{-0.36})
Ebro (Zone 2)	IPF = MMDF × (1 + 3.39 × A ^{-0.29})
Ebro (Zone 3)	IPF = MMDF × (1 + 37.73 × A ^{-0.55})

2.2.4. Fill and Steiner

Fill and Steiner [12] created a study based on Sangal’s formula and obtained values of estimated IPF that were higher than the observed values in basin areas greater than 1000 km². This problem of overestimating instantaneous peak flow led Fill and Steiner to propose an improvement to Sangal’s method. They used data from 14 stations of basins with drainage areas between 84 and 687 km² in Brazil and developed a simple formula (Equation (4)), suitable for drainage areas from 50 to 700 km², similar to Sangal’s (Equation (3)) to obtain the IPF from the mean daily flow of three consecutive days.

$$IPF = \frac{0.8 \times MMDF + 0.25 \times (Q1 + Q3)}{0.9123 \times (Q1 + Q3)/2 + 0.362} \tag{4}$$

where IPF is the estimated instantaneous peak flow (m³/s), MMDF is the maximum observed mean daily flow (m³/s), Q1 is the mean daily flow on preceding day (m³/s) and Q3 is the mean daily flow on posterior day. Further details about Equation (4) are available in Fill and Steiner (2003) [12].

2.3. Artificial Neural Network (ANN)

To estimate IPF data, we used the feedforward multilayer perceptron network (MLP), the most popular ANN in hydrology [37]. The MLP network includes an input layer, an output layer, and one

or more hidden layers. The first layer receives the input data, the hidden layers process data, and the last layer obtains the output data [38]. Each layer contains one or more neurons connected with all neurons of the next immediate layer through vertically aligned interconnections. The output y of a neuron j is obtained by computing the following Equation (5) [39]:

$$y_j = f(X \times W_j - b_j) \quad (5)$$

where, f is an activation function, X is a vector of inputs, W_j is a vector of connection weights from neurons in the preceding layer to neuron j , and b_j is a bias associated with neuron j .

During the training process with a backpropagation algorithm, the output errors are repeatedly fed back into the network to adjust connection weights and biases until optimal values are obtained [40]. The number of hidden neurons and the number of hidden layers is often determined by trial and error [41,42]. In this study, one or two hidden layers with a number of neurons between two and twenty are considered. The optimal network configuration has been determined using an iterative process, evaluating the performance for different network structures. In this process, the data sets are randomly divided into three subsets: training set (70%), validation set (15%), and test set (15%). The number of maximum training iterations (epochs) was 1000 and the Levenberg-Marquardt backpropagation algorithm [43,44] is applied to adjust the appropriate weights and minimize error.

The ANN structure used in this work is shown in Figure 2, where the input data is the maximum mean daily flow and the output data is the instantaneous peak flow. The tangent sigmoid transfer function in the hidden layers and linear transfer function in the output layer were used. We implemented and built the ANNs using MATLAB[®] software (version 8.2.0.701 (R2013b), The Mathworks, MA, USA).




Figure 2. Structure of feedforward multilayer perceptron network (MLP) network used in this research.

2.4. Adaptive Neuro-Fuzzy Inference System (ANFIS)

ANFIS models nonlinear functions and makes a nonlinear map from input space to output space using fuzzy if-then rules, with each rule describing the local behaviour of the mapping. The parameters of these rules determine the efficiency of the FIS [45] and describe the shape of the Membership Functions (MF).

In this study, the Sugeno-type FIS [46,47] was used. In this learning process, a hybrid learning algorithm—a combination of the least-squares method and the backpropagation gradient descent method—is used to emulate a given training data set and estimate the parameters of the FIS. The ANFIS architecture is based on the work of Jang (1993) [48] and it is composed of five layers. In the first layer, every node is an adaptive node and acts as an MF. Different MFs were used in this study and the models with the generalized bell and sigmoidal membership function obtained the more accurate results in the testing phase. MMDF was used as input data.

2.5. Evaluation Criteria

In this work, the performance of the different methods was evaluated using three evaluation tools. Firstly, coefficient of determination (R^2) (Equation (6)) was used to describe the degree of collinearity between estimated and observed data and the proportion of variance in observed data explained by the model [49].

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O})(E_i - \bar{E})]^2}{[(n - 1) \cdot S_O \cdot S_E]^2} \tag{6}$$

where O_i is the i th observed data, \bar{O} is the mean of the observed data, E_i is the i th estimated data, \bar{E} is the mean of the estimated data, n is the total number of observations, S_O is the variance of the observed data and S_E is the variance of the estimated data.

Secondly, root mean square error (RMSE) (Equation (7)) was used. RMSE is an error index commonly used for quantifying the estimation error and is useful in assessing the errors in the units of the data [49].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - E_i)^2}{n}} \tag{7}$$

Finally, an analysis of observed-estimated plot with the identity line (1:1 line) was used.

3. Results and Discussion

As shown in Table 3, to compare the results of the empirical formulas, R^2 and RMSE values were calculated for the fourteen gauge stations studied. The best results for each basin are highlighted in black in Table 3. The estimation with a higher R^2 value and a lower RMSE value is the best. According to the results obtained, in most of the stations, Fuller or the regionalization of Fuller’s equation (CEDEX) have the higher coefficient of determination and the lowest amount of error. It can also be concluded that the regionalization of the Fuller equation improves the estimation of the IPF, especially in basins with a high flashiness index, as demonstrated in the results obtained in AND, COT, TRE, GAR, and CUE. Besides, the Fill and Steiner formula obtained more accurate results in PER and PIT, basins characterized by a low flashiness index. The Sangal formula exhibits very regular behaviour in general, with more accurate results compared with Fill and Steiner but worse results compared with the Fuller equation or its regionalization. With regard to climate zones, a clear pattern is not observed indicating a preference of one method over another.

Table 3. Evaluation of the results of empirical formulas based on R^2 and root mean square error (RMSE) criteria.

Basin Code	R^2				RMSE (m ³ /s)			
	Fuller	CEDEX	Sangal	Fill Steiner	Fuller	CEDEX	Sangal	Fill Steiner
TRE	0.85	0.85	0.82	0.80	93.68	76.09	82.16	99.27
BEG	0.89	0.89	0.87	0.88	56.35	59.53	78.09	58.63
COT	0.70	0.70	0.68	0.68	159.65	126.11	137.51	167.11
AND	0.54	0.54	0.61	0.62	184.61	174.11	158.67	177.70
PRI	0.90	0.90	0.89	0.89	9.94	11.04	10.39	11.67
BOL	0.92	0.92	0.94	0.94	6.92	16.28	8.17	9.26
GAR	0.71	0.71	0.69	0.70	12.10	11.20	14.11	15.70
CUE	0.65	0.65	0.66	0.65	30.93	28.23	33.50	35.97
JUB	0.30	0.30	0.29	0.28	14.15	13.97	14.14	14.50
TRA	0.81	0.81	0.84	0.83	3.34	6.38	3.96	4.77
BEL	0.44	0.44	0.43	0.41	7.63	6.79	7.53	7.80
PER	0.92	0.92	0.90	0.91	17.44	20.13	19.49	16.80
RIA	0.72	0.72	0.72	0.71	4.41	3.39	3.27	3.33
PIT	0.87	0.87	0.82	0.85	4.48	16.57	2.80	2.27

Note: The best results for each basin are bold in black.

Results obtained by ANN, ANFIS, and the best empirical formula in each basin are shown in Table 4. The best results for each basin are highlighted in black. In order to construct the ANN and its accurate training, data was entered into the MATLAB software in the form of 80% training data and 20% test data. An ANN structure with two hidden layers and two hidden neurons in each layer was the optimal structure for most basins, while the second most used structure had one hidden layer with two hidden neurons. ANN, ANFIS, and empirical formulas were applied to the same gauge stations under similar conditions and compared using R^2 and RMSE as evaluation criteria. From the data in Table 4, it is evident that the highest R^2 and the lowest RMSE between simulated and observed results in most of the stations were obtained using the ANFIS method. These results support outcomes of Dastorani et al. (2013) [31] and Fathzadeh et al. (2016) [14]. With respect to the ANN method, the accuracy of ANN outputs is, in general, higher than the outputs obtained using empirical formulas, but lower compared to ANFIS results. As shown in the RIA basin data, estimations obtained using ANN are more accurate when the flow data series used as input data is longer. In general, the results obtained by machine-learning techniques (ANN and ANFIS) are clearly more accurate than those obtained by empirical formulas. Only in AND and BEG basins do the empirical formulas improve the results obtained by these techniques.

Table 4. Statistics of artificial neural networks (ANN), adaptive neuro-fuzzy inference (ANFIS) versus the best empirical formula.

Basin Code	Data Set	ANN		ANFIS		Best Empirical Formula		
		R^2	RMSE	R^2	RMSE	R^2	RMSE	Formula
TRE	Training	0.92	55.3	0.92	54.81	0.86	78.94	CEDEX
	Test	0.66	52.95	0.67	47.8	0.53	62.55	
BEG	Training	0.7	90.69	0.92	47.86	0.88	58.38	Fuller
	Test	0.83	72.03	0.87	59.31	0.95	47.07	
COT	Training	0.77	117.19	0.79	107.49	0.69	134.55	CEDEX
	Test	0.82	70.04	0.82	68.8	0.91	84.26	
AND	Training	0.46	170.75	0.5	163.13	0.53	159.13	Sangal
	Test	0.75	172.29	0.79	188.6	0.83	156.92	
PRI	Training	0.89	9.75	0.91	9	0.88	10.26	Fuller
	Test	0.98	5.62	0.98	4.8	0.96	8.52	
BOL	Training	0.97	4.6	0.99	1.7	0.95	7.48	Fuller
	Test	0.78	3.27	0.77	4.5	0.72	4.09	
GAR	Training	0.82	8.62	0.94	5.06	0.71	11.29	CEDEX
	Test	0.75	10.36	0.85	8.46	0.72	10.72	
CUE	Training	0.85	12.26	0.9	10.24	0.75	17.34	CEDEX
	Test	0.79	44.92	0.77	41.38	0.85	52.07	
JUB	Training	0.39	10.31	0.41	10.12	0.32	11.1	CEDEX
	Test	0.5	20.27	0.59	19.51	0.48	21.38	
TRA	Training	0.83	2.88	0.84	2.76	0.82	3.38	Fuller
	Test	0.83	2.66	0.8	2.7	0.83	3.15	
BEL	Training	0.49	6.44	0.6	5.61	0.47	7.12	CEDEX
	Test	0.84	6.23	0.77	7.21	0.8	7.99	
PER	Training	0.91	16.87	0.93	14.33	0.9	17.64	Fill-Steiner
	Test	0.96	7.39	0.98	5.44	0.92	9.28	
RIA	Training	0.73	3.27	0.75	3.11	0.71	3.5	Sangal
	Test	0.88	1.64	0.86	2.33	0.88	2.11	
PIT	Training	0.8	2.29	0.86	2.13	0.79	2.25	Fill-Steiner
	Test	0.92	2.2	0.97	0.82	0.97	2.07	

Note: The best results for each basin are bold in black.

Moreover, according to the plots in Figure 3, where line slope and correlation coefficient between observed and measured values of IPF obtained with ANN and ANFIS techniques are compared, ANFIS seems to be slightly better in most of the gauge stations studied because those results concentrate closer to the identity line (perfect line) and the correlation coefficient is closer to 1. However, the differences between the techniques increase when the RMSE results are analysed, as shown in Table 4.

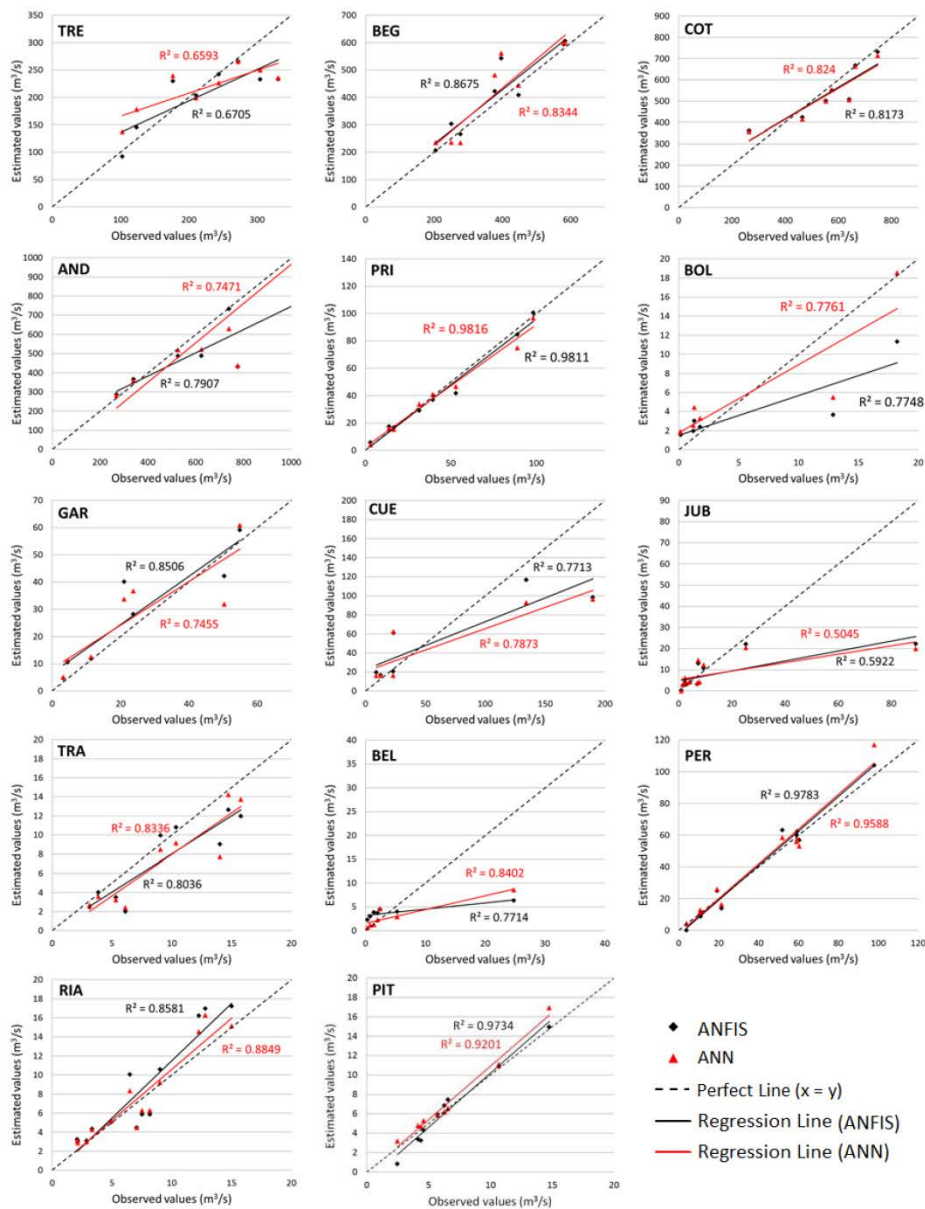


Figure 3. Scatter plots of observed instantaneous peak flow (IPF) (m^3/s) and the estimated IPF (m^3/s) obtained with ANN versus ANFIS for basins (test phase). The letters on the top left of each subfigure show the basin codes (see Table 1).

4. Conclusions

Estimation of instantaneous peak flow is essential for flood management and the design of hydraulic structures, especially in countries like Spain, where flash floods are a common occurrence and can cause significant damage. In this research, empirical formulas found in the literature and some learning-machine algorithms that have been used recently to estimate many different hydrological variables were applied to estimate IPF from MMDF. Our results show that the use of machine-learning models of the fuzzy type, such as ANFIS, are more accurate in general than ANN. These conclusions suggest that ANFIS is the more accurate method for increasing the accuracy of the estimation of IPF when a long-time series of MDF is available but the availability of IPF is shorter. The machine-learning method is superior to empirical formulas due to the data used from the basins in the case study, and future extensive studies with more data would be needed to obtain better estimators. On the other hand, the nonlinear dynamics of the relationship between IPF and MDF justifies the results obtained by the ANFIS method.

The main drawback of these machine-learning methods was the time consumed to model them. Finding the optimal structure of a neural network, the appropriate MF, and the shape of each variable in ANFIS is difficult and is determined through the process of trial and error. So, they require long tests and much greater computational resources than empirical formulas.

Acknowledgments: The first author was supported by the Catholic University of Murcia (UCAM) research scholarship program. The authors gratefully acknowledge support from the UCAM through the project “PMAFI/06/14”. This research was also partially supported by the GESINHIMPADAPT project (CGL2013-48424-C2-2-R) and by the HETEROLISTIC project (TIN2016-78799-P) with Spanish MINECO funds. We acknowledge Papercheck Proofreading & Editing Services.

Author Contributions: All authors contributed significantly to the development of the methodology applied in this study. Patricia Jimeno-Sáez and Javier Senent-Aparicio designed the experiments and wrote the manuscript; Julio Pérez-Sánchez and José María Cecilia helped to perform the experiments and reviewed and helped to prepare this paper for publication; David Pulido-Velázquez as the supervisor of Patricia Jimeno-Sáez provided many important advices on the concept of methodology and structure of the manuscript.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Gaume, E.; Bain, V.; Bernardara, P.; Newinger, O.; Barbuc, M.; Bateman, A.; Blaškovičová, L.; Blöschl, G.; Borga, M.; Dumitrescu, A.; et al. A compilation of data on European flash floods. *J. Hydrol.* **2009**, *367*, 70–78. [[CrossRef](#)]
2. Barredo, J.I. Major flood disasters in Europe: 1950–2005. *Nat. Hazards* **2007**, *42*, 125–148. [[CrossRef](#)]
3. Ding, J.; Haberlandt, U. Estimation of instantaneous peak flow from maximum mean daily flow by regionalization of catchment model parameters. *Hydrol. Process.* **2017**, *31*, 612–626. [[CrossRef](#)]
4. Fuller, W.E. Flood flows. *Trans. ASCE* **1914**, *77*, 564–617.
5. Silva, E.A. Estimativa Regional da Vazão Máxima Instantânea em Algumas Bacias Brasileiras. Master’s Thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brazil, 1997.
6. Silva, E.A.; Tucci, C.E.M. Relação entre as vazões máximas diárias e instantâneas. *Rev. Bras. Recur. Híd.* **1998**, *3*, 133–151. [[CrossRef](#)]
7. Taguas, E.V.; Ayuso, J.L.; Pena, A.; Yuan, Y.; Sanchez, M.C.; Giraldez, J.V.; Pérez, R. Testing the relationship between instantaneous peak flow and mean daily flow in a Mediterranean Area Southeast Spain. *Catena* **2008**, *75*, 129–137. [[CrossRef](#)]
8. Jarvis, C.S. Floods in United States. In *Water Supply Paper*; US Geological Survey: Reston, VA, USA, 1936.
9. Langbein, W.B. Peak discharge from daily records. *Water Resour. Bull.* **1944**, 145.
10. Linsley, R.K.; Kohler, M.A.; Paulhus, J.L.H. *Applied Hydrology*; McGraw-Hill: New York, NY, USA, 1949.
11. Sangal, B.P. Practical method of estimating peak flow. *J. Hydraul. Eng.* **1983**, *109*, 549–563. [[CrossRef](#)]
12. Fill, H.D.; Steiner, A.A. Estimating instantaneous peak flow from mean daily flow data. *J. Hydrol. Eng.* **2003**, *8*, 365–369. [[CrossRef](#)]

13. Centre for Public Works Studies and Experimentation (CEDEX). Mapa de Caudales Máximos. Memoria Técnica (In Spanish). 2011. Available online: http://www.mapama.gob.es/es/agua/temas/gestion-de-los-riesgos-de-inundacion/memoria_tecnica_v2_junio2011_tcm7--162773.pdf (accessed on 5 January 2017).
14. Fathzadeh, A.; Jaydari, A.; Taghizadeh-Mehrjardi, R. Comparison of different methods for reconstruction of instantaneous peak flow data. *Intell. Autom. Soft Comput.* **2017**, *23*, 41–49. [[CrossRef](#)]
15. Haykin, S. *Neural Networks: A Comprehensive Foundation*, 2nd ed.; Macmillan: New York, NY, USA, 1994; ISBN: 81-7808-300-0.
16. Ajmera, T.K.; Goyal, M.K. Development of stage-discharge rating curve using model tree and neural networks: An application to Peachtree Creek in Atlanta. *Expert Syst. Appl.* **2012**, *39*, 5702–5710. [[CrossRef](#)]
17. Mustafa, M.R.; Isa, M.H.; Rezaur, R.B. Artificial neural networks modelling in water resources engineering: Infrastructure and applications. *World Acad. Sci. Eng. Technol.* **2012**, *62*, 341–349.
18. Cheng, C.T.; Feng, Z.K.; Niu, W.J.; Liao, S.L. Heuristic Methods for Reservoir Monthly Inflow Forecasting: A Case Study of Xinfengjiang Reservoir in Pearl River, China. *Water* **2015**, *7*, 4477–4495. [[CrossRef](#)]
19. Govindaraju, R.S. Artificial neural networks in hydrology. II: Hydrological applications. *J. Hydrol. Eng.* **2000**, *5*, 124–137. [[CrossRef](#)]
20. Hamaamin, Y.A.; Nejadhashemi, A.P.; Zhang, Z.; Giri, S.; Woznicki, S.A. Bayesian Regression and Neuro-Fuzzy Methods Reliability Assessment for Estimating Streamflow. *Water* **2016**, *8*, 287. [[CrossRef](#)]
21. Abraham, A.; Köppen, M.; Franke, K. *Design and Application of Hybrid Intelligent Systems*; IOS Press: Amsterdam, The Netherlands, 2003; ISBN: 978-1-58603-394-1.
22. Kim, J.; Kasabov, N. HyFIS: Adaptive neuro-fuzzy inference systems and their application to nonlinear dynamical systems. *Neural Netw.* **1999**, *12*, 1301–1319. [[CrossRef](#)]
23. Emamgholizadeh, S.; Moslemi, K.; Karami, G. Prediction the groundwater level of Bastam Plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). *Water Resour. Manag.* **2014**, *28*, 5433–5446. [[CrossRef](#)]
24. Dastorani, M.; Moghadamnia, A.; Piri, J.; Rico-Ramirez, M. Application of ANN and ANFIS models for reconstructing missing flow data. *Environ. Monit. Assess.* **2010**, *166*, 421–434. [[CrossRef](#)] [[PubMed](#)]
25. Seckin, N. Modeling flood discharge at ungauged sites across Turkey using neuro-fuzzy and neural networks. *J. Hydroinform.* **2011**, *13*, 842–849. [[CrossRef](#)]
26. Tu, J.V. Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *J. Clin. Epidemiol.* **1996**, *49*, 1225–1231. [[CrossRef](#)]
27. Rezaei, H.; Rahmati, M.; Modarress, H. Application of ANFIS and MLR models for prediction of methane adsorption on X and Y faujasite zeolites: Effect of cations substitution. *Neural Comput. Appl.* **2015**, *28*, 301–312. [[CrossRef](#)]
28. Bisht, D.; Mohan-Raju, M.; Joshi, M. Simulation of water table elevation fluctuation using fuzzy-logic and ANFIS. *Comput. Model. New Technol.* **2009**, *13*, 16–23.
29. Guldal, V.; Tongal, H. Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Egirdir lake level forecasting. *Water Resour. Manag.* **2010**, *24*, 105–128. [[CrossRef](#)]
30. Shabani, M.; Shabani, N. Application of artificial neural networks in instantaneous peak flow estimation for Kharestan Watershed, Iran. *J. Resour. Ecol.* **2012**, *3*, 379–383. [[CrossRef](#)]
31. Dastorani, M.T.; Koochi, J.S.; Darani, H.S.; Talebi, A.; Rahimian, M.H. River instantaneous peak flow estimation using daily flow data and machine-learning-based models. *J. Hydroinform.* **2013**, *15*, 1089–1098. [[CrossRef](#)]
32. Kotteck, M.; Grieser, J.; Beck, C.; Rudolf, B.; Rubel, F. World Map of the Köppen-Geiger climate classification updated. *Meteorol. Z.* **2006**, *15*, 259–263. [[CrossRef](#)]
33. Senent-Aparicio, J.; Pérez-Sánchez, J.; Bielsa-Artero, A.M. Assessment of Sustainability in Semiarid Mediterranean Basins: Case Study of the Segura Basin, Spain. *Water Technol. Sci.* **2016**, *7*, 67–84.
34. Baker, D.B.; Richards, R.P.; Loftus, T.T.; Kramer, J.W. A new flashiness index: Characteristics and applications to Midwestern rivers and streams. *J. Am. Water Resour. Assoc.* **2004**, *40*, 503–522. [[CrossRef](#)]
35. Holko, L.; Parajka, J.; Kostka, Z.; Škoda, P.; Blöschl, G. Flashiness of mountain streams in Slovakia and Austria. *J. Hydrol.* **2011**, *405*, 392–401. [[CrossRef](#)]
36. Centre for Public Works Studies and Experimentation (CEDEX). Anuario de Aforos (In Spanish). Available online: <http://ceh-flumen64.cedex.es/anuarioaforos/default.asp> (accessed on 4 January 2017).

37. Maier, R.H.; Jain, A.; Graeme, C.D.; Sudheer, K.P. Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. *Environ. Model. Softw.* **2010**, *25*, 891–909. [[CrossRef](#)]
38. Hasanpour Kashani, M.; Daneshfaraz, R.; Ghorbani, M.; Najafi, M.; Kisi, O. Comparison of different methods for developing a stage–discharge curve of the Kizilirmak River. *J. Flood Risk Manag.* **2015**, *8*, 71–86. [[CrossRef](#)]
39. Govindaraju, R.S. Artificial neural networks in hydrology. I: Preliminary concepts. *J. Hydrol. Eng.* **2000**, *5*, 115–123. [[CrossRef](#)]
40. Wang, J.; Shi, P.; Jiang, P.; Hu, J.; Qu, S.; Chen, X.; Chen, Y.; Dai, Y.; Xiao, Z. Application of BP Neural Network Algorithm in Traditional Hydrological Model for Flood Forecasting. *Water* **2017**, *9*, 48. [[CrossRef](#)]
41. Meng, C.; Zhou, J.; Tayyab, M.; Zhu, S.; Zhang, H. Integrating Artificial Neural Networks into the VIC Model for Rainfall-Runoff Modeling. *Water* **2016**, *8*, 407. [[CrossRef](#)]
42. Wolfs, V.; Willems, P. Development of discharge-stage curves affected by hysteresis using time varying models, model trees and neural networks. *Environ. Model. Softw.* **2014**, *55*, 107–119. [[CrossRef](#)]
43. Levenberg, K. A Method for the Solution of Certain Problems in Least Squares. *Appl. Math.* **1944**, *2*, 164–168.
44. Marquardt, D. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Appl. Math.* **1963**, *11*, 431–441. [[CrossRef](#)]
45. Nayak, P.C.; Sudheer, K.P.; Rangan, D.M.; Ramasastri, K.S. A neuro-fuzzy computing technique for modeling hydrological time series. *J. Hydrol.* **2004**, *291*, 52–66. [[CrossRef](#)]
46. Takagi, T.; Sugeno, M. Fuzzy Identification of Systems and Its Applications to Modeling and Control. *IEEE Trans. Syst. Man Cybern.* **1985**, *15*, 116–132. [[CrossRef](#)]
47. Sugeno, M.; Kang, G.T. Structure identification of fuzzy model. *Fuzzy Sets Syst.* **1988**, *28*, 15–33. [[CrossRef](#)]
48. Jang, J.S.R. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man Cybern.* **1993**, *23*, 665–685. [[CrossRef](#)]
49. Moriasi, D.N.; Arnold, J.G.; Liew, M.W.; Binger, R.L.; Harmel, R.D.; Veith, T.L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. ASABE* **2007**, *50*, 885–890. [[CrossRef](#)]



© 2017 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

4.3 PUBLICACIÓN 3: COUPLING MACHINE-LEARNING TECHNIQUES WITH SWAT MODEL FOR INSTANTANEOUS PEAK FLOW PREDICTION

Senent-Aparicio, J., Jimeno-Sáez, P., Bueno-Crespo, A., Pérez-Sánchez, J., y Pulido-Velazquez, D. (2018). Coupling machine-learning techniques with SWAT model for instantaneous peak flow prediction. *Biosystems Engineering*, (in press)
<https://doi.org/10.1016/j.biosystemseng.2018.04.022>



ELSEVIER

Available online at www.sciencedirect.com

ScienceDirect

journal homepage: www.elsevier.com/locate/issn/15375110

Special Issue: Intelligent environments

Research Paper

Coupling machine-learning techniques with SWAT model for instantaneous peak flow prediction

Javier Senent-Aparicio ^{a,*}, Patricia Jimeno-Sáez ^a, Andrés Bueno-Crespo ^b,
Julio Pérez-Sánchez ^a, David Pulido-Velázquez ^{a,c}

^a Department of Civil Engineering, Catholic University of San Antonio, Campus de los Jerónimos s/n, 30107, Guadalupe, Murcia, Spain

^b Department of Computer Engineering, Catholic University of San Antonio, Campus de los Jerónimos s/n, 30107, Guadalupe, Murcia, Spain

^c Geological Survey of Spain (IGME), Granada Unit, Urb. Alcázar del Genil, 4. Edificio Zulema, 18006, Granada, Spain

ARTICLE INFO

Article history:

Published online xxx

Keywords:

Hydraulic design
Ladra river
Instantaneous peak flow
Machine learning
SWAT

A correct estimation of the instantaneous peak flow (IPF) is crucial to reducing the consequences of flash floods. An approach to estimate the IPF, obtained by combining Soil and Water Assessment Tool (SWAT) simulation and machine-learning models, was proposed and then verified by comparison with observation-based results in the Ladra river basin, northwest Spain. The SWAT model has been used to estimate the maximum mean daily flow (MMDF), and machine-learning models have been used to estimate the IPF based on MMDF. Four nonlinear time-series intelligence models, artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS), support vector machine (SVM) and extreme learning machine (ELM) were applied, and their results were compared. The Modified Nash-Sutcliffe efficiency coefficient (MNSE) and the index of agreement (d) were used to evaluate SWAT performance while simulating MMDF, and the coefficient of determination (R^2) and the root mean square error (RMSE) were employed to evaluate the performance of these intelligent systems. According to the results, the SWAT hydrological model is a useful tool to simulate MMDF. Validation analyses resulted in values of statistical indexes (MNSE = 0.64 and d = 0.95). Regarding intelligent systems, the results show that they can be successfully used in predicting IPF, but ELM has demonstrated a superior ability to estimate IPF from the MMDF (R^2 = 0.86 and RMSE = 48.59). The results of this study can contribute to predicting IPF in areas where sub-daily observational data are scarce, thereby reducing uncertainties associated with IPF estimations.

© 2018 IAgrE. Published by Elsevier Ltd. All rights reserved.

* Corresponding author.

E-mail address: jsenent@ucam.edu (J. Senent-Aparicio).<https://doi.org/10.1016/j.biosystemseng.2018.04.022>

1537-5110/© 2018 IAgrE. Published by Elsevier Ltd. All rights reserved.

Please cite this article in press as: Senent-Aparicio, J., et al., Coupling machine-learning techniques with SWAT model for instantaneous peak flow prediction, *Biosystems Engineering* (2018), <https://doi.org/10.1016/j.biosystemseng.2018.04.022>

Nomenclature

ALPHA_BF	Baseflow recession constant
ANFIS	Adaptive neuro-fuzzy inference system
ANN	Artificial neural network
CN2	SCS runoff curve number
CNCOEF	Plant ET curve number coefficient
CH_K1	Effective hydraulic conductivity in tributary channel alluvium
CH_K2	Effective hydraulic conductivity in main channel alluvium
CH_N1	Manning's roughness in main channel
d	Index of agreement
DEM	Digital elevation model
ELM	Extreme learning machine
EPCO	Plant uptake compensation factor
ESCO	Soil evaporation compensation factor
FIS	Fuzzy inference system
GW_DELAY	Groundwater delay
GWQMN	Threshold depth of water in the shallow aquifer for return flow to occur
HRU	Hydrologic response unit
IGN	National Center for Geographic Information
IPF	Instantaneous peak flow
LM	Levenberg–Marquardt algorithm
MLP	Multilayer perceptron network
MMDF	Maximum mean daily flow
MNSE	Modified Nash–Sutcliffe efficiency coefficient
OV_N	Manning's "n" value for overland flow
Q5	Flow with a probability of exceedance equal to 5%
R ²	Coefficient of determination
RCHRG_DP	Deep aquifer percolation fraction
REVAPMN	Threshold depth of water in the shallow aquifer for percolation to the deep aquifer
RMSE	Root mean square error
SCI	Site of community importance
SLFN	Single-layer feedforward neural network
SLSUBSN	Average slope length
SOL_AWC	Available water capacity of the soil layer
SUFI-2	Sequential uncertainty fitting programs algorithm
SVM	Support vector machine
SWAT	Soil and water assessment tool
SWAT-CUP	Calibration/uncertainty or sensitivity program interface for SWAT

flash floods (Jimeno-Sáez, Senent-Aparicio, Pérez-Sánchez, Pulido-Velázquez, & Cecilia, 2017). Traditionally, flood frequency has been analysed based on gauged flood peaks and by applying statistical analyses. In cases where long records of observed streamflow data are not available, continuous simulation modelling such as the Soil and Water Assessment Tool (SWAT) can be used to increase the record length (Lee, Heo, Lee, & Kim, 2017). However, SWAT simulation is based on a daily time step; as such, the SWAT model cannot represent IPF on a time scale of hours or minutes. Therefore, to overcome this problem, different artificial intelligence techniques can be used to estimate the IPF from the maximum mean daily flow (MMDF) based on the nonlinear relationships between these variables. MMDF can be defined as the mean daily flow registered during the day when the IPF was recorded. Therefore, an approach to estimating the IPF, obtained by combining SWAT simulations and machine-learning models, will be proposed in this work and then verified by comparison with observation-based results. The results of this study can contribute to predicting IPF in ungauged basins using artificial intelligence techniques to identify and train the model with homogeneous nearby basins and to estimating the IPF with different climate inputs (Valizadeh et al., 2017). It can be assumed that the runoff response to a given rainfall input in two different basins would be similar if similar rainfall/runoff processes occur (Ding & Haberlandt, 2017). Regionalisation methods are beyond the scope of this study, but more details can be found in Rao and Srinivas (2006).

The SWAT model is one of the most widely used hydrologic models (Mannschatz, Wolf, & Hülsmann, 2016), and many previous studies have proved its capability for modelling runoff (Gassman, Reyes, Green, & Arnold, 2007). SWAT has been successfully and widely used throughout the world with different purposes such as for the evaluation of water resources, water quality assessment, land use and cover change as well as for climate change impact assessment (Krysanova & White, 2015). Regarding the estimation of IPF, Lee et al. (2017) assessed the effects of a dam on flood frequency by combining SWAT simulations with an empirical equation used to estimate IPF from MMDF. Nevertheless, to our knowledge, SWAT has not yet been used in combination with intelligent systems to obtain IPFs that can be used for hydraulic design.

Intelligent systems have been successfully applied to environmental applications, including water resources, solar radiation and energy applications (Wang et al., 2017a). Regarding the hydrological context, the use of artificial neural network (ANN) modelling for sediment estimation and discharge forecasting has increased over the last decades (Agarwal, Mishra, Ram, & Singh, 2006; Mustafa, Isa, & Rezaur, 2012; Nayebi, Khalili, Amin, & Zand-Parsa, 2006). According to the references consulted, the adaptive neuro-fuzzy inference system (ANFIS) can also be suitable for modelling nonlinear dynamic hydrological systems (Gong, Zhang, Lan, & Wang, 2016). Support vector machine (SVM) has rarely been used in a hydrological context (Vapnik, 1998). However, Misra, Oommen, Agarwal, Mishra, and Thompson (2009) compared SVM and ANN to simulate runoff and sediment yield on daily, weekly and monthly scales and concluded that SVM could be an efficient alternative to ANN. At a later date, a novel

1. Introduction

Estimation of the frequency and magnitude of the instantaneous peak flow (IPF) is critical for flood risk assessment and for designing hydraulic structures (Ding & Haberlandt, 2017). Over the period 1950–2005, Spain was the European country most affected by flash floods (Barredo, 2007). The application of techniques aimed at reducing the uncertainties associated with IPF estimations is required to prevent damage caused by

intelligent system approach named the extreme learning machine (ELM) was presented by Huang, Zhu, and Siew (2004). As can be seen in Huang, Huang, Song, and You (2015), this technique has been successfully applied in biomedical data analysis, computer vision, image processing and system modelling and prediction. Nevertheless, the applications of ELM to forecast streamflow are scarce (Deo & Sahin, 2016; Rezaie-Balf & Kisi, 2017).

This study tested the utility of coupling intelligent systems and SWAT simulations for IPF estimation. Therefore, the main objectives of this study were (1) to assess the suitability of the SWAT model to simulate the daily streamflow in the study area; (2) to investigate the performance of different intelligent systems (ANN, ANFIS, SVM and ELM) to predict the IPF from the MMDf; and (3) to test the utility of coupling the SWAT model with intelligent systems to improve IPF forecasting.

2. Description of the study area

The Ladra river basin is a protected ecosystem in the Atlantic region in the Iberian Peninsula. It is located in northwest Spain, within the “Terras do Miño” Biosphere Reserve (declared a reserve in 2002 by UNESCO), and was selected as a Site of Community Importance (SCI) by the European Union due to its high ecological value. This basin has an area of 843 km² and is characterised by a quick rainfall-to-runoff response due to a predominantly low permeable bedrock and a moderate slope. The elevations range from 392 m a.s.l. at the basin outlet to 906 m a.s.l. at the headwater. The study area is characterised by an oceanic climate with all-year-round mild temperatures and dry summer seasons. The annual mean rainfall is around 1300 mm with a coefficient of variation of 0.18 over the period 1966–2014. The annual mean temperature is around 11 °C, with a minimum in February and a maximum in August.

The study area includes a mixture of relatively natural and agricultural areas, with small rural areas interspersed (Sánchez-Hernández, Vieira-Lanero, Servia, & Cobo, 2011). As can be seen in Fig. 1b, the Ladra river basin is dominated by forests, which cover 64% of the area. Other land uses are agricultural (35%) and artificial surfaces (1%). Soil data from the Harmonized World Soil Database with a resolution of 1 km by 1 km were used to determine the soil types. In spite of their coarse resolution, we consider that these data are adequate for the purpose of this research. A recent study by Ye, Zhang, and Viney (2011) evaluated the effect of soil data resolution on the SWAT model in a humid watershed in China and concluded that improvements in the resolution of the soil data do not necessarily contribute to a more accurate prediction of streamflow in humid watersheds. The predominant soil types are Humic Cambisols (64%). Other soil types present are Umbric Leptosols (12%) and Ferric Podzols (6%) (Fig. 1d). From a geological standpoint, the study area is characterised by two main blocks: granitic rocks, which occupy around 25% of the area; and metamorphic rocks (mainly schist and slates), which occupy 68% of the total area.

3. Methodology

To achieve the objectives stated above, this study is divided into two parts. In the first, the SWAT model was calibrated and validated in the study area to increase the record length of mean daily flow. Then, the performance of different intelligent systems was analysed to estimate the IPF from the MMDf.

3.1. Streamflow estimation using SWAT model

3.1.1. SWAT model description

SWAT is a watershed scale, semi-distributed and physically-based hydrological model that operates on a daily time step (Arnold, Srinivasan, Muttiah, & Williams, 1998). The model is designed to simulate the impacts of management practices in watersheds with varying land use, soils and management conditions. SWAT is based on the concept of hydrologic response units (HRUs) that consist of homogeneous land cover, slope and soil characteristics. Each HRU generates an amount of runoff that is routed to calculate the bulk runoff. For a detailed review of the physical processes modelled within SWAT, refer to Neitsch, Arnold, Kiniry, and Williams (2011). The balance equation used is:

$$SW_t = SW_0 + \sum_{i=1}^t (R_{day} - Q_{surf} - E_a - W_{seep} - Q_{gw})_i \quad (1)$$

where SW_t is the final soil water content; SW_0 is the initial soil water content; t is the time (days); R_{day} is the precipitation on day i ; Q_{surf} is the surface runoff; E_a is the evapotranspiration on day i ; W_{seep} is the percolation on day i ; and Q_{gw} is the amount of baseflow on day i (all in mm).

3.1.2. Input data and model set-up

The open-source QGIS interface for SWAT, QSWAT, version 2012, was employed for the study (Dile, Daggupati, George, Srinivasan, & Arnold, 2016). Delineation of the Ladra watershed and its stream network was based on a digital elevation model (DEM) obtained from the National Center for Geographic Information (IGN) with a 25-m grid cell resolution. Following the FAO criteria (FAO, 1980), slopes were divided into three groups (<8%, 8–30%, >30%). Land cover was extracted from the European project Corine Land Cover 2012. Climate data, including daily total precipitation (mm) and maximum and minimum air temperature (°C), were provided by the regional meteorological agency (Meteogalicia, 2017). In this study, the Hargreaves method was used to simulate potential evapotranspiration (Hargreaves, 1994). The subdivision into HRUs was performed using threshold levels of 10% to eliminate minor soils, slopes and land uses. Using this threshold, the Ladra river basin was finally discretised into 11 sub-basins, including 124 HRUs, with 6–20 per sub-basin.

3.1.3. SWAT model calibration and validation

In this study, the Sequential Uncertainty Fitting programs algorithm (SUFI-2) (Abbaspour, 2012) was used in the calibration and sensitivity analysis for streamflow simulation. The SWAT model was calibrated using daily streamflow data measured

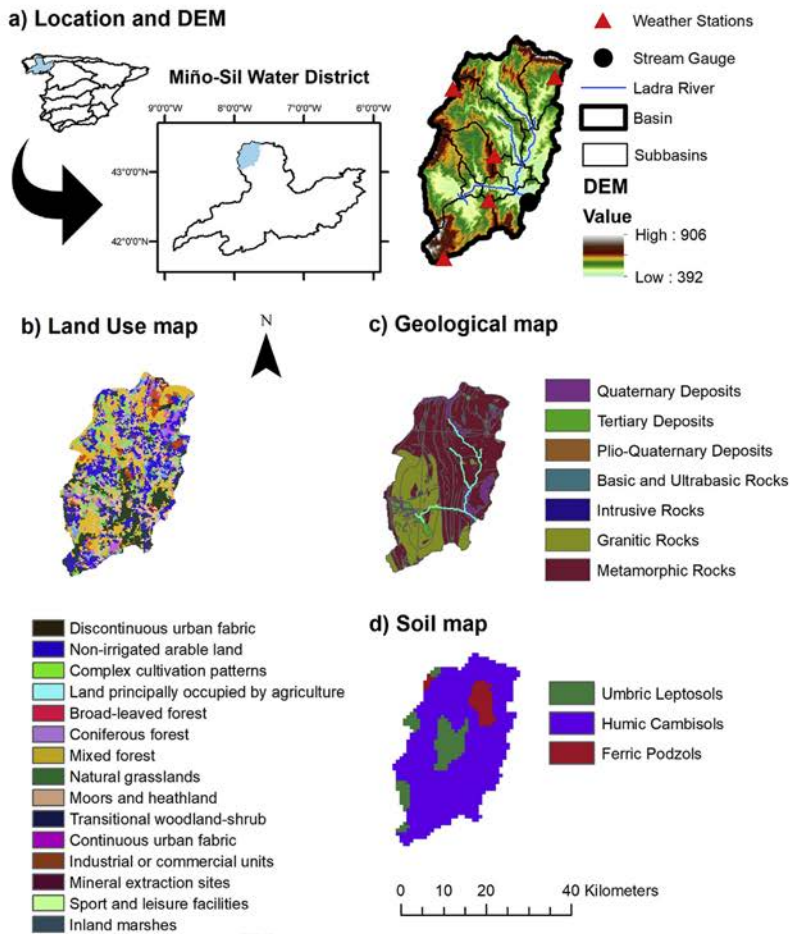


Fig. 1 – DEM and location of the Ladra river basin in the Miño-Sil Water District.

at the Begonte gauge station (Fig. 1). According to Krause, Boyle, and Båse (2005), to increase the sensitivity to high flows, and due to the fact that only the high flows are of interest, a modified Nash-Sutcliffe (MNSE) efficiency index was used as an objective function. The model was set up from 2001 to 2012; the first 3 years were used to warm up the model to mitigate the effects of the initial conditions on the model output. The period from 2004 to 2009 was designed as the calibration period, and the period from 2010 to 2012 was used for validation. A total of 2000 simulations were performed by SWAT Calibration and Uncertainty Programs (SWAT-CUP). A more detailed description of SWAT-CUP and SUFI2 can be found in Abbaspour (2012).

3.1.4. SWAT model evaluation

Two statistical measures, MNSE and the modified index of agreement (d), were used to compare the model streamflows

with the real streamflow from the Begonte gauging station (Fig. 1a), as follows in Equation (2) and Equation (3):

$$MNSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (2)$$

$$d = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n [(P_i - \bar{O}) + (O_i - \bar{O})]^2} \quad (3)$$

where O_i is the observed value; \bar{O} is the mean value of the observed streamflow; P_i is the simulated value; and n is the number of observations. Nash Sutcliffe Efficiency and the index of agreement are usually based on the square differences between observed and simulated values. In this study,

following the suggestions of Krause et al. (2005), these differences are cubed (see Equation (2) and Equation (3)). In this way we are increasing the sensitivity of the efficiency criteria to high flows since these are of primary concern in this study.

3.2. Machine learning algorithms

The algorithms used in this study will be described briefly in the following paragraphs.

3.2.1. Artificial neural network (ANN)

The ANN involves massively parallel-distributed information processing based on theories of the human mental and neural structure and functions (Hsieh, 1993). It is composed of a set of nodes (neurons) organised in layers and connected by links. An ANN can model the relationships between the independent and dependent variables (Luk, Ball, & Sharma, 2000). The particular advantage of the ANN is that the network can be trained to learn these relationships without requiring *a priori* knowledge of the process' physical characteristics (Minns & Hall, 1996). This feature makes ANNs an effective tool for modelling complex hydrological processes (Talebizadeh & Moridnejad, 2011).

In this paper, the multilayer perceptron (MLP) network was used. It is a feedforward backpropagation network and is the most popular topology used traditionally in applications in hydrology and water resources (Maier, Jain, Graeme, & Sudheer, 2010).

The MLP consists of one input layer in which input data are fed into the network, one or more hidden layer(s) in which data are processed and one output layer which produces output data for the given inputs. Each layer contains one or more neurons connected with all neurons in the next immediate layer; each link has an associated weight that represents the connection strength. Each node receives input signals; the summation of the weighted input signals is transferred by a nonlinear activation function to produce an output (Srivastava, McNair, & Johnson, 2006). An MLP with one hidden layer can be defined by the following Equation (4) (Lima, Cannon, & Hsieh, 2016):

$$\hat{y}_j = \sum_{i=1}^L \beta_i \cdot f(w_i \cdot x_j + b_i) + \beta_0 \quad (j = 1, \dots, N) \quad (4)$$

where \hat{y}_j is the model output; N and L are the number of cases and hidden neurons, respectively; β_i and β_0 are the weight and bias parameters in the output layer; f is an activation function; x_j is the input model; and w_i and b_i are the weight and bias in the hidden layer of the L hidden neurons.

During the training process with a backpropagation algorithm, the result of network \hat{y}_j is compared with the observed data y_j , and the network error is calculated; the output errors are repeatedly propagated backwards through the network to adjust connection weights, and biases until optimal values are obtained (Amirhossien, Alireza, Kazem, & Mohammadbagher, 2015; Wang et al., 2017b). For training MLP networks, the Levenberg–Marquardt algorithm (LM) (Levenberg, 1944; Marquardt, 1963) was used to calculate the gradient of the error function and to reduce iteratively the mean squared error. Studies on streamflow forecasting (Kisi, 2007; Yaseen,

El-Shafie, Jaafar, Afan, & Sayl, 2015) have shown that the LM algorithm is appropriate in training MLP networks; it takes a small fraction of the time taken by other algorithms for training, and ANN trained with LM gives the best results if compared to other models.

3.2.2. Adaptive neuro-fuzzy inference system (ANFIS)

The ANFIS model was first introduced by Jang (1993). It integrates the reasoning ability of the fuzzy inference system (FIS) and the learning capability of ANN. This combination allows FIS to learn from the data in order to create an efficient model to determine the behaviour of imprecisely defined complex dynamical systems (Kim & Kasabov, 1999). An FIS is a computational framework that combines the concept of fuzzy logic, fuzzy decision rules and fuzzy reasoning (Jang & Sun, 1995), and this allows for describing language and human reasoning in the context of mathematics (Firat, Turan, & Yurdusev, 2009). Therefore, ANFIS may be a better option than ANN if the input data of the ANFIS model make a nonlinear map from input space to output space using fuzzy if-then rules; these rules describe the local behaviour of the mapping. This model involves the following steps: (i) input characteristics are mapped to input membership functions; (ii) these membership functions are related to rules, which are related to a set of output characteristics; (iii) the output characteristics are mapped to output membership functions; and, finally, (iv) these output membership functions are related to a single output (Jang, Sun, & Mizutani, 1997). There are two common methods for formulating this mapping: Sugeno-type (Sugeno & Kang, 1988; Takagi & Sugeno, 1985) and Mamdani-type (Mamdani & Assilian, 1975) fuzzy inference system (FIS). In this study, the Sugeno-type FIS was used because it is more computationally efficient and compact, and consequently it is more appropriate for optimisation and for adaptive techniques to construct fuzzy models (Jang & Gulley, 1995). The Sugeno fuzzy structure in the ANFIS model is composed of five layers. For training model parameters, a hybrid learning algorithm, which represents a combination of the least-squares method and the backpropagation gradient descent method, is used. This algorithm emulates a given training data set and discovers patterns hidden inside it (Talebizadeh & Moridnejad, 2011). The membership functions most commonly used in the literature are triangular, trapezoidal, Gaussian, generalised bell and sigmoidal functions (Nguyen, Prasad, Walker, & Walker, 2003). In this study, these different types of membership functions were tried until the best training performance was found. The more accurate results were obtained using the generalised bell membership function in the testing phase.

3.2.3. Support vector machine (SVM)

SVM (Cortes & Vapnik, 1995) is a nonlinear kernel-based regression method based on statistical learning theory. The application of SVM in nonlinear regression estimation is increasing because of good generalisation performance (Cao & Tay, 2003). SVM maps the input data into a high-dimensional feature space by nonlinear mapping, and then the complex nonlinear regression of the input space can be theoretically solved by using a simple linear regression (Gong et al., 2016). For a given training set of N samples $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$,

where x denotes the input vector and y is its corresponding output, the SVM estimator finds a regression function f that best describes the observed output y with an error tolerance ϵ , evaluated as the following:

$$f(x) = w \cdot \Phi(x) + b \quad (5)$$

where Φ is a nonlinear function by which x is mapped into a feature space; w is a weight vector; and b is a bias constant. The values of w and b are estimated by solving an optimisation problem.

3.2.4. Extreme learning machine (ELM)

ELM is a universal approximator for a wide range of random computational nodes, and all the hidden node parameters can be randomly generated according to any continuous probability distribution without any prior knowledge. It is a learning algorithm for single-layer feedforward neural networks (SLFNs). ELM has several advantages compared to traditional popular gradient-based learning algorithms such as back-propagation for feedforward neural networks (Huang, Zhu, & Siew, 2006): (1) the learning speed with ELM is much faster; (2) it tends to produce better generalisation performance; (3) SLFNs with non-differentiable activation functions can be trained; and (4) ELM tends to reach solutions without local minima, overfitting or improper learning, etc.

First, in the ELM approach (Huang et al., 2006; Lima et al., 2016), input weights (w_i) and hidden layer biases (b_i) (see Equation (4)) of SLFNs can be randomly assigned if the activation functions in the hidden layer are infinitely differentiable. Thus, only the β parameters need to be optimised during the training process. Second, according to Huang (2014), the β_0 term is not necessary. SLFNs training is a linear system simplifying the problem of finding the least-squared solution as

$$H\beta = Y \quad (6)$$

where H is the hidden layer output matrix of dimension $N \times L$; β are the weights connecting the hidden layer and the output layer matrix of dimension $L \times m$, with m equal to the number of output nodes; and Y is the target data matrix of dimension $N \times m$. Finally, the H matrix is computed, and the output layer weights β are determined analytically via the Moore–Penrose generalised inverse operation of the hidden layer output matrix H . The optimal output weight layer $\hat{\beta}$ is given by:

$$\hat{\beta} = H^\dagger Y \text{ with } H^\dagger = PH^T \text{ and } P = (H^T H)^{-1} \quad (7)$$

with H^\dagger being the Moore–Penrose pseudo-inverse of matrix H , and P being the inverse of the covariance matrix of matrix H .

3.2.5. Evaluation criteria

Two statistical parameters, coefficient of determination (R^2) and root mean square error (RMSE), were used to evaluate the effectiveness of the ANN, ANFIS, SVM and ELM models in this study. These parameters are defined in Equations (8) and (9):

$$R^2 = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (8)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (9)$$

where O_i is the observed value; \bar{O} is the mean value of the observed streamflow; P_i is the simulated value; \bar{P} is the mean value of the simulated streamflow; and n is the total number of observations.

4. Results and discussion

4.1. Estimation of MMDF using SWAT model

The first step in the calibration was to identify those parameters that are most influential in governing the streamflow. To achieve this, a global sensitivity analysis was conducted with 19 flow-related parameters. In this sensitivity analysis, all parameters are changing, and a large number of runs are needed in order to see the impact of each parameter on the objective function (Abbaspour, Vaghefi, & Srinivasan, 2018). A ranking of parameter sensitivities was obtained after 500 runs, thus eliminating the parameters identified as not sensitive. The most sensitive parameters are listed in Table 1. Later, a realistic value-range obtained from the experience and hydrological knowledge of the basin was introduced for the most sensitive parameters in the SWAT-CUP programme to make an autocalibration using the SUFII algorithm.

Analysis of the calibrated parameters indicated in Table 1 shows that the SCS runoff curve number (CN2) increased by 15% compared to the default value, thereby decreasing the infiltration and increasing the runoff. Available water capacity of the soil layer (SOL_AWC) was reduced by 18% in all soils to increase the movement of water within the soil profiles (Qiu, Zheng, & Yin, 2012). The soil evaporation compensation coefficient (ESCO) was reduced after calibration from 0.95 to 0.70, increasing the ability of the model to extract evaporative demand from lower soil layers. According to Abbaspour et al. (2015), these changes in CN2, SOL_AWC and ESCO were expected in order to increase simulated peak flows. The plant uptake compensation factor (EPCO) was also reduced after calibration, increasing the evapotranspiration generated by the model. The value of the baseflow recession constant (ALPHA_BF) obtained for the Ladra river basin (0.07) indicates a rapid response of runoff to rainfall for the low-permeability geological formations in the basin. The calibrated values of other groundwater parameters, such as threshold depth of water in the shallow aquifer for return flow to occur (GWQMN), groundwater delay (GW_DELAY) and threshold depth of water in the shallow aquifer for percolation to the deep aquifer (REVAPMN), were very similar to those used by Malagó, Pagliero, Bouraoui, and Franchini (2015) for NW Spanish watersheds. In fact, GW_DELAY was greatly decreased during calibration, as is consistent with the fast response to wet episodes observed in the observed hydrographs of the Ladra river basin. Deep aquifer percolation fraction (RCHRG_DP) is very close to zero due to the fact that geological formations do not favour a durable (and relevant) groundwater storage. The high value of Mannings's "n" value

Table 1 – Calibrated model parameters.

Parameter	Description	Range	Initial value	Adjusted value
CN2	SCS runoff curve number (dimensionless)	20–90	61–83	+15.71%
GWQMN	Threshold depth of water in the shallow aquifer for return flow to occur (mm)	0–5000	1000	452.88
ALPHA_BF	Baseflow recession constant (days ⁻¹)	0–1	0.048	0.0681
CNCOEF	Plant ET curve number coefficient (dimensionless)	0.5–2	1	0.7645
GW_DELAY	Groundwater delay (days)	0–500	31	1.1704
RCHRG_DP	Deep aquifer percolation fraction (dimensionless)	0–1	0.05	0.0313
REVAPMN	Threshold depth of water in the shallow aquifer for percolation to the deep aquifer (mm)	0–500	500	48.85
SOL_AWC	Available water capacity of the soil layer (mm mm ⁻¹)	0–1	0.12–0.16	–18.48%
ESCO	Soil evaporation compensation factor (dimensionless)	0–1	0.95	0.7027
EPCO	Plant uptake compensation factor (dimensionless)	0–1	1	0.3778
SLSUBBSN	Average slope length (m)	10–150	24–92	+0.04%
OV_N	Mannings's "n" value for overland flow (dimensionless)	0.01–1	0.1	0.7529
CH_K1	Effective hydraulic conductivity in tributary channel alluvium (mm hr ⁻¹)	0–300	0	44.18
CH_K2	Effective hydraulic conductivity in main channel alluvium (mm hr ⁻¹)	0–150	0	140.93
CH_N1	Mannings's roughness in main channel (dimensionless)	0.01–0.3	0.014	0.2901

for overland flow (OV_N) is related to the abundant vegetation such as in NW Spain (Raposo, Dafonte, & Molinero, 2013).

Taking into account the fact that the range of the MNSE lies between 1 (perfect fit) and $-\infty$, while the range of d lies between 1 (perfect fit) and 0 (no correlation), the results shown in Table 2 demonstrate that the performance of the calibrated model was satisfactory in reproducing peak flows.

Using the simulated daily flows for the period 1973–2014, the flow duration curve was plotted and compared with that from the observed daily flows (Fig. 2). This curve can be used as a graphical measure to illustrate the SWAT model performance in replicating the higher values of the discharge (Shrestha, Shrestha, & Shrestha, 2017). As expected, due to the objective function used in the model calibration, there is an overprediction with regards to the lower probability of exceedance. Nevertheless, the 5th percentile flows (Q5), which were equalled or exceeded for 5% of the period 1973–2014, were simulated with reasonable accuracy. Given the fact that our goal is to obtain a good performance in replicating the higher values of the discharge, we can accept these results.

4.2. Estimation of IPF using machine-learning techniques

MATLAB software (R2016a) was used to develop, train and test the machine-learning techniques. To estimate the IPF, 5-fold cross-validation was performed to evaluate the performance of machine-learning techniques. The data set was divided into 5 subsets, and the holdout method was repeated 5 times. Each time, one of the 5 subsets was used as the test set and the other 4 subsets were put together to form a training set. Then, R^2 and RMSE (mean and standard deviation) across all 5 trials were computed.

Table 2 – Initial values, calibration and validation statistics for daily streamflow.

Initial values		Calibration		Validation	
MNSE	d	MNSE	d	MNSE	d
-0.25	0.67	0.68	0.93	0.64	0.95

The performances of ANN, ANFIS, SVM (linear kernel) and ELM (Gaussian kernel) models were compared after training and testing. Table 3 shows the results of statistical analysis in terms of R^2 and RMSE. According to these results, ANN, ANFIS, SVM (linear kernel) and ELM (Gaussian kernel) were characterised by mean R^2 values of 0.80, 0.81, 0.89 and 0.91 during the training periods and 0.74, 0.69, 0.88 and 0.86 for the testing periods. Based on the obtained R^2 , the four models produced acceptable results for both periods; SVM and ELM showed the best performance, and ANFIS showed the worst. In terms of the RMSE, the results were similar to R^2 and ELM, with Gaussian kernel showing the best performance. These results are in agreement with those obtained by Bezdah, Asghari, Eazi, and Palhang (2009), who found that the prediction accuracy of the high-value discharges using SVM was better than those obtained with models like ANN or ANN integrated with genetic algorithms.

4.3. Coupled application of the SWAT model and the ELM technique for IPF prediction

Once it was demonstrated that the SWAT model was able to reproduce MMDF and that ELM was the best option to reproduce IPF from MMDF, the coupled application of both techniques was used for IPF prediction. As can be seen in Fig. 3, the calibrated SWAT model was applied for the period 1973–2014, when real IPFs were available, thus obtaining 41 MMDF. Next, the trained ELM model was used to estimate IPF.

Figure 4 shows the simulated and observed IPF for the study period. These results show the robustness of the combined application of the SWAT model and the ELM technique. The simulated IPFs were underestimated compared to the observed data, but the R^2 value between the observed and estimated data was 0.54, which represents a suitable performance. These results are consistent with previous studies (Sudheer, Nayak, & Ramasastri, 2003) that also found an underestimation in the prediction of the IPF using machine-learning techniques.

Due to the great influence of the record length and quality of IPF data on flood design (Ding, Wallner, Müller, &

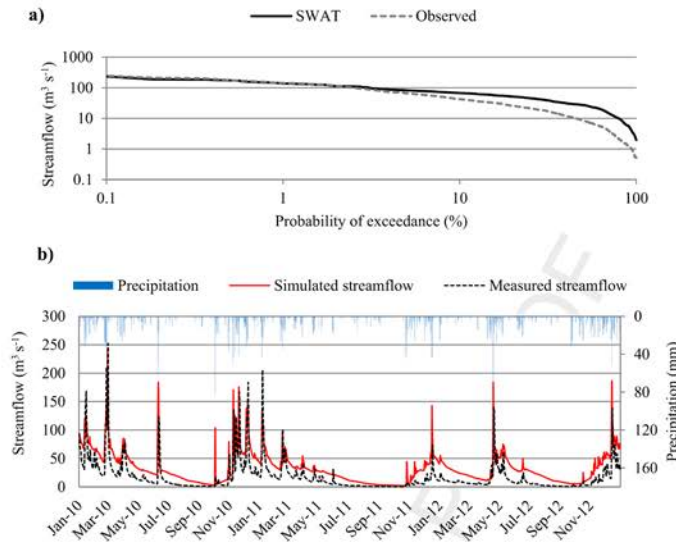


Fig. 2 – Comparison of the observed and simulated streamflows in the validation period at the Ladra river basin; a) flow duration curve, b) daily hydrographs.

Table 3 – Training and test statistics (mean ± standard deviation) for IPF estimation.

Statistics	Stage	ANN	ANFIS	SVM	ELM
R ²	Training	0.80 ± 0.16	0.81 ± 0.18	0.89 ± 0.03	0.91 ± 0.02
	Test	0.74 ± 0.37	0.69 ± 0.35	0.88 ± 0.15	0.86 ± 0.12
RMSE	Training	67.27 ± 25.71	65.29 ± 30.81	56.29 ± 5.49	59.96 ± 16.54
	Test	86.00 ± 82.32	106.30 ± 76.60	55.51 ± 23.74	48.59 ± 4.80

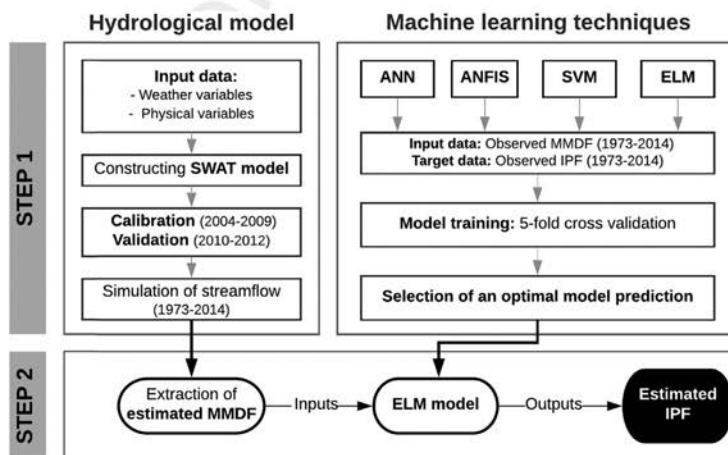


Fig. 3 – Flow diagram for the coupled application of SWAT model and ELM technique to predict IPF.




Fig. 4 – Comparison of observed and simulated IPF (m^3/s) for the period (1973–2014) at the Ladra river basin. The dashed line is the 1:1 line, while the line of best fit would be $y = 0.3942x + 100.26$.

Haberlandt, 2016), the coupled application of these techniques can be a solution to extend IPF the data series in basins with poor data records.

5. Conclusions

The accurate and reliable estimation of peak flow magnitude is one of the most important issues in hydrologic infrastructure design. This study explored the possibility of coupling a SWAT model with machine-learning techniques to obtain the magnitude of IPF, which is critical for flood risk assessment. The main findings are as follows:

- 1) The comparison between simulated maximum mean daily flows with the corresponding observed flows indicated that the use of the SWAT model was suitable for estimating peak flows at a daily time scale in the Ladra river basin. The SWAT model reproduced the daily mean flow in the basin while accurately producing, during the validation period, an acceptable modified Nash-Sutcliffe Efficiency (MNSE = 0.64) and a good index of agreement ($d = 0.95$).
- 2) To overcome the inability of the SWAT model to obtain instantaneous peak flows, different intelligent systems were evaluated. As a result of this evaluation, all the machine-learning techniques investigated in this study can be used in the prediction of IPF, though ELM performed slightly better than all the other methods, with a root mean square error of 48.59 and coefficient of determination of 0.86.
- 3) The results of this study can contribute to predicting IPF in areas where data at sub-daily time scales are scarce or not available, thereby reducing the uncertainties associated with IPF estimations.

Acknowledgements

The second author was supported by the Catholic University of Murcia (UCAM) research scholarship program. The authors

gratefully acknowledge support from the UCAM through the project "PMAFI/06/14". This research was also partially supported by the Spanish MINECO under grant TIN2016-78799-P (AEI/FEDER, UE). We acknowledge Papercheck Proofreading & Editing Services.

REFERENCES

- Abbaspour, K. C. (2012). *SWAT-CUP 2012. SWAT calibration and uncertainty analysis program - a user manual*. Dübendorf, Switzerland: Swiss Federal Institute of Aquatic Science and Technology.
- Abbaspour, K. C., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H., & Klove, B. (2015). A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *Journal of Hydrology*, 524, 733–752.
- Abbaspour, K. C., Vaghefi, S. A., & Srinivasan, R. (2018). A guideline for successful calibration and uncertainty analysis for soil and water assessment: A review of papers from the 2016 International SWAT Conference. *Water*, 10, 6.
- Agarwal, A., Mishra, S. K., Ram, S., & Singh, J. K. (2006). Simulation of runoff and sediment yield using artificial neural networks. *Biosystems Engineering*, 94(4), 597–613.
- Amirhossien, F., Alireza, F., Kazem, J., & Mohammadbagher, S. (2015). A comparison of ANN and HSPF models for runoff simulation in Balkhichai river watershed, Iran. *American Journal of Climate Change*, 4, 203–216.
- Arnold, J. G., Srinivasan, R., Muttiyah, R. S., & Williams, J. R. (1998). Large area hydrologic modeling and assessment part I: Model development. *Journal of the American Water Resources Association*, 34(1), 73–89.
- Barredo, J. I. (2007). Major flood disasters in Europe: 1950–2005. *Natural Hazards*, 42, 125–148.
- Bezdash, M., Asghari, K., Eazi, M., & Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36, 7624–7629.
- Cao, L. J., & Tay, F. E. H. (2003). Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on Neural Networks*, 14(6), 1506–1518.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.

- Deo, R. C., & Sahin, M. (2016). An extreme learning machine model for simulation of monthly mean streamflow water level in eastern Queensland. *Environmental Monitoring and Assessment*, 188, 90.
- Dile, Y. T., Daggupati, P., George, C., Srinivasan, R., & Arnold, J. (2016). Introducing a new open source GIS user interface for the SWAT model. *Environmental Modelling & Software*, 85, 129–138.
- Ding, J., & Haberlandt, U. (2017). Estimation of instantaneous peak flow from maximum daily flow by regionalization of catchment model parameters. *Hydrological Processes*, 31, 612–626.
- Ding, J., Wallner, M., Müller, H., & Haberlandt, U. (2016). Estimation of instantaneous peak flows from maximum mean daily flows using the HBV hydrological model. *Hydrological Processes*, 30, 1431–1448.
- Firat, M., Turan, M. E., & Yurdusev, M. A. (2009). Comparative analysis of fuzzy inference systems for water consumption time series prediction. *Journal of Hydrology*, 374(4), 235–241.
- Gassman, P. W., Reyes, M. R., Green, C. H., & Arnold, J. G. (2007). The soil and water assessment tool: Historic development, applications, and future research directions. *Transactions of the ASABE*, 50(4), 1211–1250.
- Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A comparative study of artificial neural networks, support vector machines and adaptive neuro fuzzy inference system for forecasting groundwater levels near Lake Okeechobee, Florida. *Water Resources Management*, 30(1), 375–391.
- Hargreaves, G. H. (1994). Defining and using reference evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 120, 1132–1139.
- Hsieh, C. (1993). Some potential applications of artificial neural systems in financial management. *Journal of Systems Management*, 44(4), 12.
- Huang, G. B. (2014). An insight into extreme learning machines: Random neurons, random features and kernels. *Cognitive Computation*, 6, 376–390.
- Huang, G., Huang, G. B., Song, S., & You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61, 32–48.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004). Extreme learning machine: A new learning scheme of feedforward neural networks. In *IEEE International Joint Conference on neural networks* (Vol. 2, pp. 985–990).
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70, 489–501.
- Jang, J. S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23, 665–685.
- Jang, J. S. R., & Gulley, N. (1995). *Fuzzy logic toolbox user's guide*. Natick, MA, USA: The Mathworks, Inc.
- Jang, J. S. R., & Sun, C. T. (1995). Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3), 378–406.
- Jang, J. S. R., Sun, C. T., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. New Jersey, USA: Prentice-Hall.
- Jimeno-Sáez, P., Senent-Aparicio, J., Pérez-Sánchez, J., Pulido-Velázquez, D., & Cecilia, J. M. (2017). Estimation of instantaneous peak flow using machine-learning models and empirical formula in Peninsular Spain. *Water*, 9, 347.
- Kim, J., & Kasabov, N. (1999). HyFIS: Adaptive neuro-fuzzy inference systems and their application to nonlinear dynamical systems. *Neural Networks*, 12, 1301–1319.
- Kisi, O. (2007). Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering*, 12, 532–539.
- Krause, P., Boyle, D. P., & Báse, F. (2005). Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5, 89–97.
- Krysanova, V., & White, M. (2015). Advances in water resources assessment with SWAT -an overview. *Hydrological Sciences Journal*, 60, 771–783.
- Lee, J. E., Heo, J. H., Lee, J., & Kim, N. W. (2017). Assessment of flood frequency alteration by dam construction via SWAT simulation. *Water*, 9, 264.
- Levenberg, K. A. (1944). Method for the solution of certain problems in least squares. *Quarterly of Applied Mathematics*, 2, 164–168.
- Lima, A. R., Cannon, A. J., & Hsieh, W. W. (2016). Forecasting daily streamflow using online sequential extreme learning machines. *Journal of Hydrology*, 537, 431–443.
- Luk, K. C., Ball, J. E., & Sharma, A. A. (2000). A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*, 227, 56–65.
- Maier, R. H., Jain, A., Graeme, C. D., & Sudheer, K. P. (2010). Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. *Environmental Modelling & Software*, 25, 891–909.
- Malagó, A., Pagliero, L., Bouraoui, F., & Franchini, M. (2015). Comparing calibrated parameter sets of the SWAT model for the Scandinavian and Iberian peninsulas. *Hydrological Sciences Journal*, 60(5), 949–967.
- Mamdani, E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7, 1–13.
- Mannschatz, T., Wolf, T., & Hülsmann, S. (2016). Nexus Tools Platform: Web-based comparison of modelling tools for analysis of water-soil-waste nexus. *Environmental Modelling & Software*, 76, 137–153.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431–441.
- Meteogalicia (2017). <http://www.meteogalicia.gal/>.
- Minns, W., & Hall, M. J. (1996). Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal*, 41, 399–417.
- Misra, D., Oommen, T., Agarwal, A., Mishra, S. K., & Thompson, A. M. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 103, 527–535.
- Mustafa, M. R., Isa, M. H., & Rezaur, R. B. (2012). Artificial neural networks modeling in water resources Engineering: Infrastructure and applications. *International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*, 6(2), 128–136.
- Nayebi, M., Khalili, D., Amin, S., & Zand-Parsa, S. (2006). Daily stream flow prediction capability of artificial neural networks as influenced by minimum air temperature data. *Biosystems Engineering*, 95(4), 557–567.
- Neitsch, S. L., Arnold, J. G., Kiniry, J. R., & Williams, J. R. (2011). *Soil and water assessment tool theoretical documentation, version 2009*. Temple: Texas Water Resources Institute.
- Nguyen, H. T., Prasad, N. R., Walker, C. L., & Walker, E. A. (2003). *A first course in fuzzy and neural control*. New York, USA: Chapman & Hall/CRC Press.
- Qiu, L., Zheng, F., & Yin, R. (2012). SWAT-based runoff and sediment simulation in a small watershed, the loessial hilly-gullied region of China: Capabilities and challenges. *International Journal of Sediment Research*, 27, 226–234.
- Rao, A. R., & Srinivas, V. V. (2006). Regionalization of watersheds by fuzzy cluster analysis. *Journal of Hydrology*, 318(1–4), 57–79.
- Raposo, J. R., Dafonte, J., & Molinero, J. (2013). Assessing the impact of future climate change on groundwater recharge in Galicia-Costa, Spain. *Hydrogeology Journal*, 21, 459–479.
- Rezaie-Balf, M., & Kisi, O. (2017). New formulation for forecasting streamflow: Evolutionary polynomial regression vs. extreme learning machine. *Hydrology Research*. nh2017283.

- Sánchez-Hernández, J., Vieira-Lanero, R., Servia, M. J., & Cobo, F. (2011). Feeding habits of four sympatric fish species in the Iberian Peninsula: Keys to understanding coexistence using prey traits. *Hydrobiologia*, 667(1), 119–132.
- Shrestha, S., Shrestha, M., & Shrestha, P. K. (2017). Evaluation of the SWAT model performance for simulating river discharge in the Himalayan and tropical basins of Asia. *Hydrology Research*. <http://hr.iwaponline.com/content/early/2017/04/21/nh.2017.189>.
- Srivastava, P., McNair, J. N., & Johnson, T. E. (2006). Comparison of process-based and artificial neural network approaches for streamflow modeling in an agricultural watershed. *Journal of the American Water Resources Association*, 42, 545–563.
- Sudheer, K. P., Nayak, P. C., & Ramasastri, K. S. (2003). Improving peak flow estimates in artificial neural network river flow models. *Hydrological Processes*, 17(3), 677–686.
- Sugeno, M., & Kang, G. T. (1988). Structure identification of fuzzy model. *Fuzzy Sets and Systems*, 28, 15–33.
- Takagi, T., & Sugeno, M. (1985). Identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15, 116–132.
- Talebizadeh, M., & Moridnejad, A. (2011). Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models. *Expert Systems with Applications*, 38(4), 4126–4135.
- Valizadeh, N., Mirzaei, M., Allawi, M. F., Afan, H. A., Mohd, N. S., Hussain, A., et al. (2017). Artificial intelligence and geo-statistical models for stream-flow forecasting in ungauged stations: State of the art. *Natural Hazards*, 86(3), 1377–1392.
- Vapnik, V. N. (1998). *The nature of statistical learning theory*. New York: Springer.
- Wang, L., Kisi, O., Hu, B., Bilal, M., Zounemat-Kermani, M., & Li, H. (2017a). Evaporation modelling using different machine learning techniques. *International Journal of Climatology*, 37, 1076–1092.
- Wang, J., Shi, P., Jiang, P., Hu, J., Qu, S., Chen, X., et al. (2017b). Application of BP neural network algorithm in traditional hydrological model for flood forecasting. *Water*, 9, 48.
- Yaseen, Z. M., El-Shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530, 829–844.
- Ye, X., Zhang, Q., & Viney, N. R. (2011). The effect of soil data resolution on hydrological processes modelling in a large humid watershed. *Hydrological Processes*, 25, 130–140.

4.4 PUBLICACIÓN 4: COMBINED USE OF GEOSTATISTIC AND HYDROLOGICAL MODELS FOR A PRELIMINARY ASSESSMENT OF “UNDER-CATCH” AND PRECIPITATION PATTERN IN ALPINE BASINS (CANALES BASIN, SIERRA NEVADA, SPAIN).

Jimeno-Sáez, P., Pulido-Velazquez, D., Cuellar, M.P., Pardo-Igúzquiza, E., Collados-Lara, A.J., Senent-Aparicio, J. Combined use of geostatistic and hydrological models for a preliminary assessment of “under-catch” and precipitation pattern in alpine basins (Canales Basin, Sierra Nevada, Spain), (under review).

1 **Combined use of geostatistic and hydrological models for a preliminary**
2 **assessment of “under-catch” and precipitation pattern in alpine basins**
3 **(Canales Basin, Sierra Nevada, Spain).**
4

5 P. Jimeno-Sáez¹, D. Pulido-Velazquez^{2,1}, M.P. Cuellar³, E. Pardo-Igúzquiza⁴, A.J.
6 Collados-Lara², J. Senent-Aparicio¹

7 Affiliations of authors:

8 (1) Department of Civil Engineering, Catholic University of San Antonio (UCAM),
9 Campus de los Jerónimos s/n, 30107, Guadalupe, Murcia, Spain. E-mails:
10 pjimeno@ucam.edu, jsenent@ucam.edu

11 (2) Instituto Geológico y Minero de España, Urb. Alcázar del Genil, 4.
12 Edificio Zulema Bajo, 18006, Granada (Spain). E-mails: d.pulido@igme.es,
13 aj.collados@igme.es

14 (3) Department of Computer Science and Artificial Intelligence, University of Granada.
15 C/. Pdta. Daniel Saucedo Aranda s.n. Granada (Spain). E-mail: manupc@decsai.ugr.es

16 (4) Instituto Geológico y Minero de España, Ríos Rosas, 23, 28003 Madrid (Spain). E-
17 mail: e.pardo@igme.es

18

19 **Abstract**

20 Gauges modify the wind fields, producing important under-catch in solid precipitation.
21 For this reason solid precipitation measurements show important biases with respect to
22 the real values, especially in windy conditions. In this work we propose a methodology
23 that combines geostatistic and hydrological models to perform a preliminary assessment
24 of global under-catch and precipitation pattern (distribution between solid and liquid
25 phase and spatial gradient with the elevation) in alpine regions. It is based on the
26 available information about daily natural streamflow and daily climatic data
27 (precipitation and temperature) in the catchment. We want to analyse long time periods
28 in order to take into account the stochastic behaviour of the natural streamflow and the
29 climatic variables. A preliminary assessment of temperature and precipitation fields is
30 performed by applying different geostatistical approaches assuming some hypothesis
31 about the relationship between climatic fields and altitude. The generated fields are
32 employed as inputs of a conceptual hydrological model, which includes two parameters

33 to correct respectively the solid and liquid precipitation. The parameters are calibrated
34 minimizing the difference between the simulated and historical natural streamflows.
35 The model is validated and its results allow to achieve the next objectives: to identify
36 the best combination of geostatistical and hydrological models to approximate
37 streamflows, to perform a global assessment of the under-catch of solid and liquid
38 precipitation and to assess precipitation pattern in term of solid and liquid precipitation
39 and spatial gradient with the elevation. It has been applied in the Canales Basin, an
40 alpine catchments of Sierra Nevada (Spain).

41 **Keywords:** solid precipitation, under-catch, gradient of precipitation, conceptual
42 hydrological models, Sierra Nevada

43

44 **1. Introduction**

45 Solid precipitation measurement shows important biases with respect to the real values
46 due to under-catch phenomenon. This phenomenon, especially significant in windy
47 conditions, depends on some relevant physical processes that affect systematic error of
48 precipitation measurement in the gauges (Goodison et al., 1998; Groisman and Legates,
49 1994; Rasmussen et al., 2012; Sevruk, 1981; Sevruk et al., 2009). These errors have
50 long been recognized as affecting all types of precipitation gauges (Yang et al., 1995)
51 and are mainly associated with the wind field deformation above the gauge orifice,
52 wetting and evaporation losses on the internal walls of the gauge and splashing of
53 raindrops or blowing of snow into or out of the gauge (Goodison et al., 1998; Sevruk,
54 1982) and their aggregation usually yield underestimation of precipitation (Adam and
55 Lettenmaier, 2003; Groisman and Legates, 1994; Sevruk, 1982). The under-catch issue
56 has been studied for years. Already in 19th century, early works (Jevons, 1861;
57 Symons, 1864) on how the wind causes gauges to catch less. Later, Alter (1937) and

58 Wilson (1954) showed that precipitation measurements from gauges properly protected
59 from wind are much more reliable. Sevruk (1982) considered wetting and evaporating
60 losses as well as wind-induced loss and estimated the wind effects decreases the amount
61 of snowfall measurements up to 50 per cents or even more. Wind is the largest source of
62 errors (Benning and Yang, 2005; Sevruk et al., 2009) and this effect can be reduced by
63 the use of wind shields but not eliminated (Buisán et al., 2017). Many authors
64 (Goodison et al., 1998; Groisman et al, 1991; Groisman and Legates, 1994; Yang et al.,
65 1995) have recognized the need to correct these systematic errors, especially for solid
66 precipitation, for their effects on hydrological and climatological studies. Sevruk (1982)
67 published his works about methods for correcting systematic errors in precipitation
68 measurements for operational use. Later, Legates (1987) modified a model proposed by
69 Sevruk and Hamon (1984) to develop a general bias adjustment equation. In 1985, the
70 World Meteorological Organization (WMO) has performed different tests in the
71 framework of different projects. They started developing Solid Precipitation
72 Intercomparison Experiment between 1987 and 1993 with the aim of calibrating any
73 type of precipitation gauges (Goodison et al., 1998). Many countries have accepted the
74 proposal of WMO, in which they assessed and derived adjustment functions for solid
75 precipitation measurement (Adam and Lettenmaier, 2003). More recently in the
76 framework of the WMO-SPICE project (2012-2015) they are also analyzing more
77 deeply similar issues They are mainly focus on measuring the precipitation amount,
78 precipitation intensity, and precipitation type (liquid, solid, mixed), over various time
79 periods (minutes, hours, days, season) (Nitu, 2013). They will also address the linkage
80 with snow on the ground (snow depth); as snow depth measurements are closely tied to
81 snowfall measurements, that is, assessing the performance of automated precipitation
82 gauges (Nitu, 2013). Recent studies focusing in this issue can be found in the literature;

83 Rasmussen et al. (2012) studied the relative accuracies of different instrumentation,
84 gauges and windshield configurations to measure snowfall. Wolff et al. (2015)
85 determined the wind-induced under-catch of solid precipitation. Qualitative analyses
86 and Bayesian statistics are used to evaluate and objectively choose the model that best
87 describes the data. Buisan et al. (2017) adjusted a functions based on the relationships
88 between catch ratio and wind speed and temperature to evaluate underestimation of
89 snowfall in the Pyrenees mountain range of Spain.

90 Several studies have analysed the effects of preliminary phase of precipitation bias
91 corrections on runoff and water balance (Fekete et al., 2004; Stisen et al., 2012; Tian et
92 al., 2007). Only some of them are focused on the correction of precipitation at basin
93 scale. For example, Valery et al. (2009) and Bartolini et al. (2011) obtained snow under-
94 catch correction as a solution of an inverse problem of the hydrological cycle, which
95 minimised the difference between observed and simulated discharge through a simply
96 water balance models. Sherestha et al. (2014) obtained the optimal value of correction
97 by minimizing differences between observed and simulated discharges and snow cover
98 areas. Li et al. (2015) developed a model integrated in a HBV model and used two
99 corrected factor parameters, one for snow and other for liquid precipitation, where the
100 objective function is the difference between simulated and observed daily discharge and
101 glacier annual mass balance. Irannezhad et al. (2015) and Akanegbu et al. (2017) used a
102 similar degree day method to model snowmelt process and obtained the corrector factor
103 using to calibrate the observed snow water equivalent (SWE) and observed SWE and
104 runoff respectively.

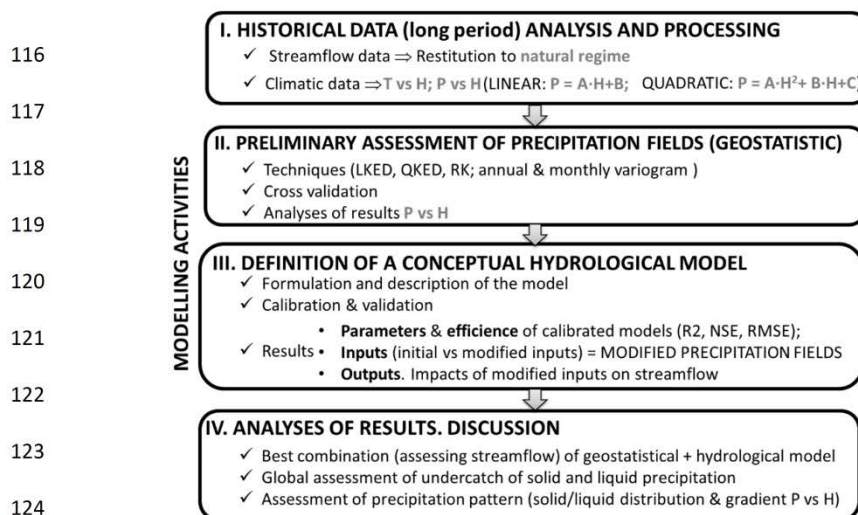
105 In this work we propose a novel research based on a combined use of different
106 geostatistic approaches and a conceptual hydrological model to minimize differences
107 between estimated and historical natural stream-flow. It allows to perform a preliminary

108 global assessment of global under-catch and precipitation patterns (distribution between
109 solid and liquid phase and spatial gradient with the elevation) in alpine basins.

110 The paper has been organized in 5 sections. Section 2 describes the proposed
111 methodology. Section 3 includes the description of the case study and the available data.
112 Section 4 shows the results which are discussed in section 5. Finally, the conclusions
113 are summarized in section 6.

114 2. Method

115 A flowchart of the methodology is represented in Figure 1.



125 **Figure 1.** Flow chart of the methodology

126 2.1 Historical data analyses and processing

127 We intend to model and analyse natural streamflow. In order to obtain these natural
128 series we need to remove the anthropic influences from the streamflow measurements in
129 the gauges, which can require more or less difficult mathematical operations depending
130 on the case (Escriba-Bou et al., 2017).

131 In the proposed method it is important to have data for a long enough period in order to
132 perform an assessment taking into account the stochastic behaviour of the streamflow
133 and the climate variables.

134 Based on the experimental climatic data we can also assess the pattern of the
135 precipitation measurements in term of variability of the mean values with the altitude.

136 **2.2 Preliminary assessment of precipitation and temperature fields (geostatistic).**

137 We propose to apply Geostatistical methods, which are commonly used to assess
138 climatic fields because they take into account the spatial correlation between the
139 experimental data through the variogram function (Chiles and Delfiner, 1999;
140 Matheron, 1963). Sometimes considering secondary information in the estimation
141 procedure can help to reduce the uncertainty in the estimated fields since the available
142 information is usually limited. Climatic variables (precipitation and temperature) are
143 normally related with elevation. This variable can be used as secondary information in
144 the estimation procedure. In this study, in order to consider elevation as secondary
145 information, we have considered two geostatistics techniques: (1) Kriging with external
146 drift (KED) where the relationship between the target variable and elevation is
147 integrated in the kriging process as external drift that influences the kriging parameters
148 and (2) Regression Kriging (RK) which integrates the secondary information through a
149 regression model. Then the estimation is improved using ordinary Kriging (OK) of
150 regression residuals.

151 **2.3 Definition of a conceptual Hydrological model**

152 Attending to the spatial resolution the hydrological models can be classified in lumped
153 (global assessment assuming homogeneous parameters) and distributed models (spatial
154 assessment including heterogeneous conditions and the spatial distribution of the

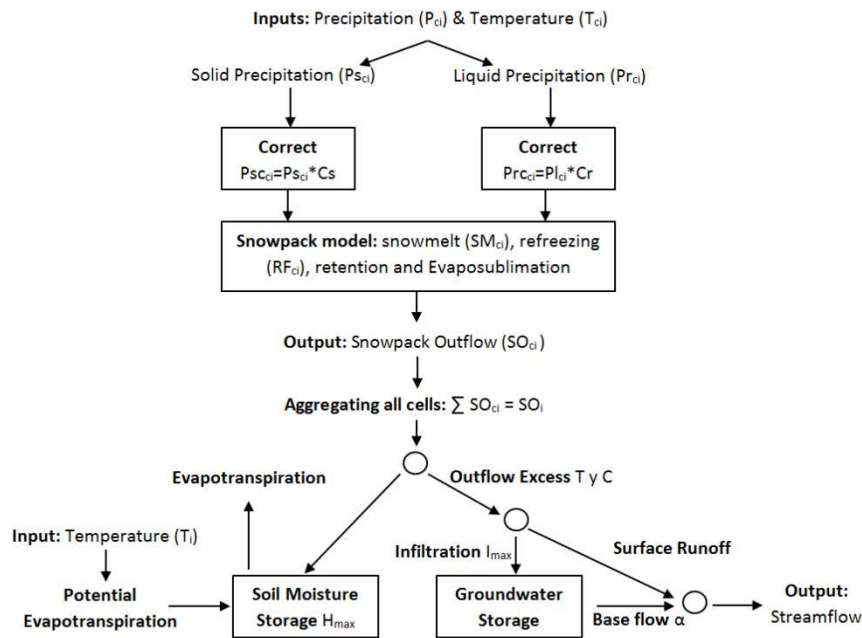
155 actions). In this work we only consider in a distributed way the hydrological processes
156 related with the snow. In the scientific literature we can find different snow modelling
157 approaches: interpolation methods (e.g., Collados-Lara et al., 2017; Richer et al., 2013;
158 Sexstone and Fassnacht, 2014), evolutionary algorithms (e.g., Pardo-Iguzquiza et al.,
159 2017), conceptual (e.g., HBV (Lindström et al., 1997); SRM (Martinec et al., 2008);
160 (Sensoy and Uysal, 2012)) or more physically based model (e.g., CROCUS (Bruland et
161 al., 2001); ECHAM (Foster et al., 1996) approaches. In this work we propose to apply a
162 new hydrological balance model, the Snow-Témez model (STM), developed by
163 coupling a hybrid temperature index snow model (Hock, 2003; Kuusisto, 1984; Orozco-
164 Medina, 2014), with Témez lumped rainfall-runoff model (Jódar et al., 2017; Témez,
165 1977). This coupling is necessary because Témez model not consider snow
166 accumulation and melting processes, which are common in alpine areas. The inputs of
167 the model are the Precipitation (P) and temperature (T). The distributed conceptual
168 snow model that we have proposed is based on the model described by Irannezhad et al.
169 (2015) which consists of two sub-models (precipitation and snowpack sub-models)
170 Firstly, the fractions of solid precipitation (Ps) and liquid precipitation (Pr) are
171 calculated in precipitation sub-model. Then, the amounts of Ps and Pr are corrected
172 using the correction coefficients of rain gauge measurement including wind speed
173 effects. Cr is the correction coefficient for rainfall and Cs is the correction coefficient
174 for snowfall. Secondly, the snowpack sub-model is used to calculate different snowpack
175 hydrological processes. It considers the next hydrological processes related with the
176 snow: accumulation of solid water, snowmelt (SM), evaposublimation, refreezing (RF)
177 and amount of retained liquid water in the snowpack. The SM is based on temperature-
178 index or degree-day factor method, based on empirical relationship between melt rates
179 and air temperature (Hock, 2003; Kuusisto, 1984), which assumes a linear relationship

180 between surface air temperature and snowmelt rate in a catchment. Some of the main
181 advantages of temperature-index snowmelt model (Hock, 2003) are that they use
182 datasets that are usually available in most catchments (temperature and precipitation)
183 and they provide good results despite its simplicity are. In this research we propose to
184 simulate the fusion process by applying a hybrid degree-day approach (Orozco-Medina,
185 2014; Smith et al., 2013), which, although it is not an energy balance model, considers
186 in a simplified way the influence of some key variables related with the energy balance.
187 In this case we assumed that the monthly melting rates are proportional to the global
188 shortwave radiation index with clear sky (which allows to define a parsimonious
189 approach of the spatio-temporal variability of the melting rates). Finally, the obtained
190 snow model outputs (SO) are aggregated for all cells to define the inputs of the lumped
191 rainfall-runoff model.

192 The rainfall-runoff Temez model is a simple lumped model that has been successfully
193 applied in Spanish basins (Bejarano et al., 2010; Escrivá-Bou et al., 2017; Estrela and
194 Quintas, 1996; Jódar et al., 2017). The Temez model operates by performing moisture
195 balances between the different processes that take place in the hydrological system and
196 considers two storage tanks, the soil or unsaturated zone and the aquifer (Escrivá-Bou,
197 2017; Murillo and Navarro, 2011). Total runoff is the sum of a rapid response (surface
198 runoff) and a slow response from groundwater storage (base flow) (Escrivá-Bou, 2017).
199 A fraction of liquid precipitation and snowmelt flux enter in the soil and it is partially
200 lost as evapotranspiration. The water excess runs off the surface and partitioned into
201 direct surface runoff and infiltration. These processes are mainly controlled by the next
202 parameters: H_{\max} (maximum soil moisture capacity), C (threshold to generate runoff),
203 I_{\max} (maximum infiltration) and α (discharge parameter of aquifer).

204 Both models, the snow model and the Témez model, preserve the water balance, being
205 the change in water storage within the system (groundwater storage) equal to the
206 difference between the water inputs and outputs. Therefore, we can add correction
207 factors to the precipitation inputs (solid and liquid precipitation fields) in order to assess
208 how much the precipitation fields should be modified in order to improve natural
209 stream-flow simulation. Therefore, by feeding them with the climatic fields described in
210 the previous section we can obtain a preliminary global assessment of the under-
211 catching phenomenon based on the streamflow. It also allows to identify the best geo-
212 statistical approach to assess the spatial pattern of precipitation fields in order to assess
213 the global under-catch that minimize differences with natural stream-flow.

214 Figure 2 shows a schematic representation of the Hybrid Snow-Témez model where the
215 subscript c and i denote the variables associate with cell c for time i . The first step of the
216 model related to the snow works in a distributed way (by cells) and the second step
217 works in an lumped way (aggregating the results of all the cells for each time i).



218

219 **Figure 2.** Schematic representation of the Hybrid Snow-Témez model (STM).

220 We intend to perform an automatic calibration of the parameters of these models.

221 Classical and useful methods of automatic optimization, such as the Rosenbrock

222 methods (Rosenbrock, 1960) and the simplex methods (Nelder and Mead, 1965) are

223 limited by initial value ranges of parameters (Wu et al., 2017). Therefore, they are only

224 used as local optimization algorithms (Gupta and Sorooshian, 1985). To avoid the limits

225 of local search, we have used a global optimization algorithm, such as the Shuffled

226 Complex Evolution (SCE-UA) algorithm (Duan et al., 1994). SCE-UA has a powerful

227 capability of calibrating the rainfall-runoff model (Duan et al., 1994; Zhang and Shi,

228 2011). SCE-UA combines many advantages of the genetic algorithm (GA) and the

229 simplex methods. GA is designed with random search strategy and thus is a global

230 optimization algorithm. The objective function is to obtain the minimum of sum of the

231 differences between observed and simulated daily streamflow series.

232 Calibration of models was done using the calibration data sets (2000–2012). Then, we
 233 tested the models with the validation sets (1988–1999).

234 Our optimization experiments with the hybrid snow-hydrological model allow to
 235 estimate the model parameters, including the correction factor for the precipitation,
 236 which can be useful as a preliminary assessment of the global under-catch in the basin.
 237 The performance of the different experiments was evaluated using the Nash-Sutcliffe
 238 efficiency (NSE) (Nash and Sutcliffe, 1970), coefficient of determination (R^2) and root
 239 mean square error (RMSE). These evaluation criteria are shown by the next equations.

$$\text{NSE} = 1 - \frac{\sum_{i=1}^n (O_i - E_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (1)$$

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O})(E_i - \bar{E})]^2}{[(n-1) \cdot S_O \cdot S_E]^2} \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (O_i - E_i)^2}{n}} \quad (3)$$

240 where O_i is the i th observed data, E_i is the i th estimated or simulated data, \bar{O} and \bar{E} are
 241 the mean values of observed series and simulated series, n is the total number of
 242 observations, S_O is the variance of the observed data and S_E is the variance of the
 243 simulated data.

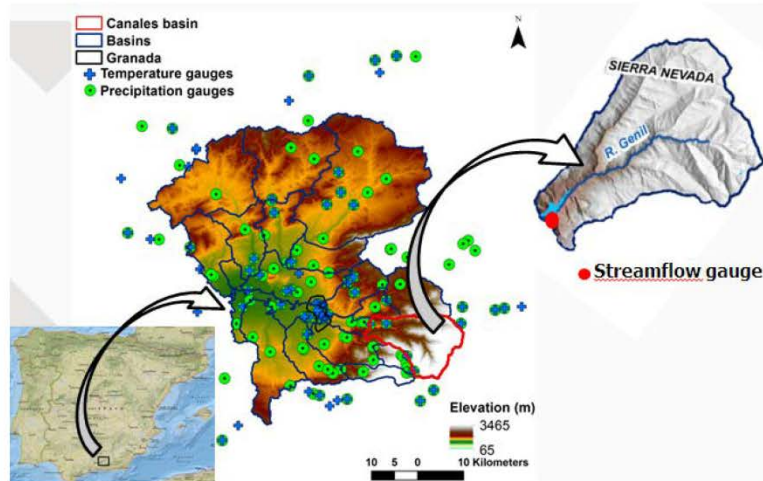
244 The estimated invariant correction factor for the precipitation will allow us to assess
 245 modified inputs (corrected precipitation fields) that improve model efficiency. We can
 246 also assess the sensitivity of the results to the correction of the precipitation fields.

247 The procedure allows to identify the best combination of geostatistical approach and
 248 hydrological model to estimate streamflows in an alpine basin. Base on the precipitation
 249 correction factor we can also obtain a global assessment of the under-catch of solid and
 250 liquid precipitation. Finally we can also assess the precipitation patter (distribution
 251 between solid and liquid precipitation and gradient of precipitation with elevation) in

252 accordance with the corrected precipitation fields. It allows to assess if the inversion of
253 precipitation gradient is maintained with the correction of the under-catch of it seems to
254 be due to systematic errors in the measurements.

255 3. Case study and data

256 In this research The Canales Basin will be used as case study. It is an Alpine Catchment
257 of Sierra Nevada Mountain Range located in SE Spain (See Figure 3). Sierra Nevada is
258 parallel to the Mediterranean coastline, situated at approximate latitude of 37°N and has
259 more than twenty aligned peaks over 3000 m a.s.l that divides the area into two climatic
260 zones, a northern continental and a southern Mediterranean. Canales Basin has a surface
261 of 176.3 Km², is located in the northern face of Sierra Nevada and is the headwaters of
262 the Genil River.



263

264

Figure 3. Location of the study area and data

265 Figure 3 shows the location of the gauges that provide the data that will be employed to
266 perform a global assessment of the under-catch phenomenon in the basin. These data
267 are:

268 1) Daily streamflow measurements at the end of the Basin (in the Canales Reservoir)

269 2) Daily climatic data (precipitation and temperature) in some of the 119 climatic
270 gauges existing in the area.


271 The daily discharge data of the basin were collected from the Centre for Hydrographic
272 Studies of CEDEX website (CEDEX, 2018) and are available from 1988. We have
273 employed the daily available data in the period (1988-2012). This is considered to be a
274 long enough period for this small basin in order to perform an assessment taking into
275 account the stochastic behaviour of the streamflow and the climate variables.

276 Precipitation and temperature data were provided by four Spanish agencies: “Agencia
277 estatal de meteorología” (AEMET), “Instituto de Investigación y Formación Agraria y
278 Pesquera” (IFAPA), “Parque Nacional de Sierra Nevada” (PNS) and “Red de
279 Información Ambiental de Andalucía” (REDIAM). In total 119 precipitation gauges and
280 72 temperature gauges have been used. We have employed the precipitation fields
281 obtained by Collados-Lara et al. (2018). They estimated precipitation for the Alto Genil
282 catchment (where is included the Canales basin) using KED with linear and quadratic
283 external drift and RK in order to test different possibilities to reproduce the shape of the
284 experimental data (inversion of the precipitation gradient with elevation). Moreover we
285 have estimated temperature fields for the Alto Genil catchment using KED with external
286 drift. The minimum temperature was calculated using KED, followed by OK of the
287 difference $T_{max}-T_{min}$ considering $T_{med} = (T_{max}-T_{min})/2$. These estimation fields
288 (precipitation and temperature) have been used as inputs of the the hydrological model.

289 **4. Results**

290 **4.1 Historical data analyses and processing**

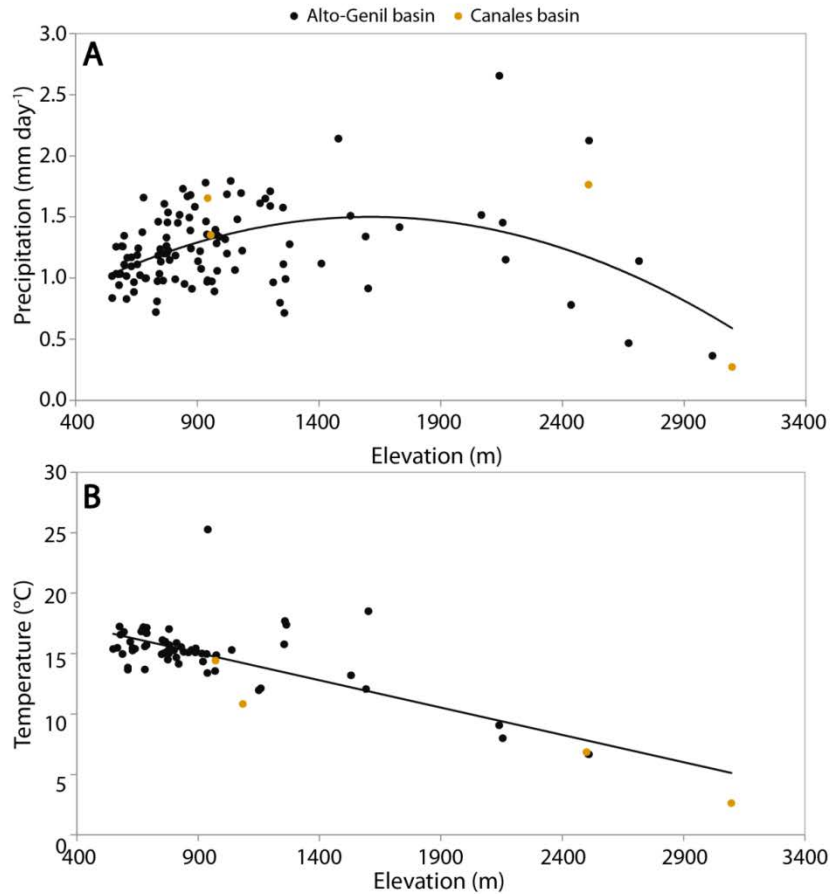
291 Figure 4 shows the natural streamflow series derived from the gauge measurements by
292 removing the anthropic influences in the Basin. In this basin, the difference between the
293 natural series and the measurement one are mainly due to detractions or derivations in
294 some channels to supply irrigation demands.



295 **Figure 4.** Natural streamflow series against measured streamflow of Canales basin

296 On the other hand, the original precipitation data also shows an inversion of gradient
297 above a threshold of 1600 m (Figure 5 A). It could be due a real precipitation patter or a
298 systematic error in the measurement due to the under-catch of precipitation. However
299 temperature shows a clear linear relation with elevation, being lower for higher
300 elevations (Figure 5 B).

301



302
303
304
305

Figure 5. Mean daily temperatura (B) and precipitation (A) data depending on the elevation in Alto Genil basin where Canales Basin is located.

306 4.2 Preliminary assessment of precipitation fields (geoestatistic)

307 Precipitation field were estimated by applying three techniques (linear KED, quadratic
308 KED and RK) with for the Alto Genil basin. Daily climatic fields in the period 1980-
309 2014 were estimated with spatial resolution of 1km x 1km by applying geostatistic
310 techniques using the data coming the available data in the 119 precipitation and 72
311 temperature gauges existing in the area (See Figure 3). The Elevation has been
312 considered as secondary variable for the estimation. The analysis of the experimental

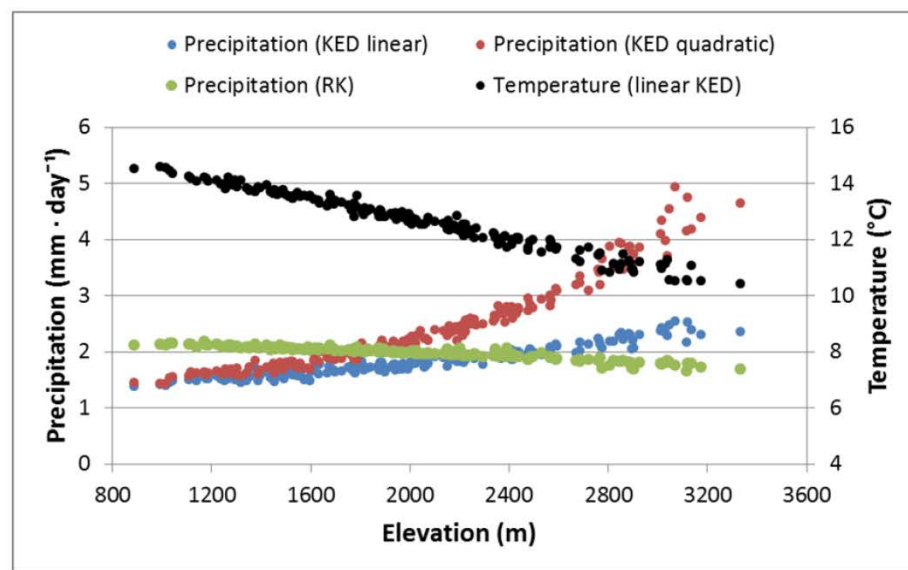
313 data showed a linear relationship between mean temperature and elevation (Figure 5B).
 314 Therefore, we decide to apply a kriging with linear external drift to estimate the
 315 temperature fields. The mean daily precipitation data show a quadratic relationship with
 316 the elevation (See Figure 5A). Different hypothesis have been considered to approach
 317 these precipitation fields by applying kriging with linear drift, with quadratic drift, and
 318 regression-kriging. We have considered two model options: Monthly and yearly
 319 variogram analysis to characterize the spatial data correlation.

320 **Table 1.** Mean squared error of the temperature ($^{\circ}\text{C}^2$) and precipitation (mm^2)
 321 estimation obtained for the cross validation experiment.

	Precipitation			Temperature	
	KEDQ	KEDL	RK	KEDL Tmin	OK Tmax-Tmin
Yearly model	23.519	10.440	12.387	5.977	10.886
Monthly model	21.386	10.194	12.347	6.043	10.786

322
 323 In terms of mean squared error (MSE) the yearly model shows worst results for all the
 324 alternatives with the exception of linear KED of minimum temperature where the yearly
 325 model is slightly better (See Table 1). For this reason the monthly model has been
 326 selected as the best approximation and has been used to obtain the inputs of the
 327 hydrological model. For precipitation the best approximation to the data is obtained
 328 with linear KED but RK reproduce better the shape of the data (inversion of
 329 precipitation gradient) for the Alto-Genil basin (Collados-Lara et al., 2018). Figure 6
 330 shows the estimated fields of precipitation and temperature versus elevation for the
 331 Canales basin. In the temperature case a clear linear decrease with elevation is observed
 332 (as the experimental data). With respect precipitation, KED techniques show increases
 333 of mean precipitation with elevation, in contrast to the RK technique where
 334 precipitation may decrease at higher elevations (negative gradient with altitude). The
 335 inversion of gradient is not observed in this figure because the inflection point was
 336 observed around from 1000 meters for the Alto Genil basin and the Canales basin has a

337 range of elevations of 900-3400 meters. The quadratic approach of the relationship
 338 between precipitation and altitude provides the worst approximations of the
 339 precipitation data. For this reason we decided to test the other two solutions (linear KED
 340 and RK) in order to identify which ones allows a better approximation of the
 341 streamflow series when they are used as inputs of the Hydrological model.



342
 343

344 **Figure 6.** Estimated mean daily temperature and precipitation data depending on the
 345 elevation in Canales Basin.

346

347

4.3 Results of the conceptual hydrid snow-Temez model

348 A summary of the results obtained with the automatically calibrated snow-Temez model
 349 in terms of correction factor for solid (Cs) and liquid (Cr) precipitation and goodness of
 350 fit to the streamflow daily data is included in the next tables (Table 1.1 and Table 1.2).
 351 It includes the different experiment defined with the different approaches of climatic
 352 fields. The numerical values of NSE, R2 and RMSE show that the efficiency of the
 353 models increases by correcting precipitation.

354 **Table 1.1** Goodness of fit to the streamflow daily data for calibration and validation

355 periods

Approaches of climatic fields	Cs	Cr	Calibration			Validation		
			NSE	R ²	RMS E	NSE	R ²	RMS E
RK	1.78	1.4	0.56	0.58	0.15	0.48	0.52	0.12
RK (Cs=Cr=1; non-recalibrated model)	1	1	0.07	0.57	0.22	0.03	0.42	0.17
RK (Cs=Cr=1; recalibrated model)	1	1	0.38	0.51	0.18	0.32	0.40	0.14
Linear KED	1.8	1.07	0.28	0.45	0.19	0.32	0.53	0.14
Linear KED (Cs=Cr=1; non-recalibrated model)	1	1	-0.03	0.38	0.23	0.38	0.48	0.13
Linear KED (Cs=Cr=1; recalibrated model)	1	1	0.05	0.36	0.22	0.36	0.46	0.14

356

357 **Table 1.2** Goodness of fit to the streamflow monthly data for calibration and validation

358 periods

Approaches of climatic fields	Cs	Cr	Calibration			Validation		
			NSE	R ²	RMS E	NSE	R ²	RMS E
RK	1.78	1.4	0.68	0.70	3.39	0.63	0.67	2.66
RK (Cs=Cr=1; non-recalibrated model)	1	1	0.06	0.70	5.79	-0.001	0.55	4.37
RK (Cs=Cr=1; recalibrated model)	1	1	0.46	0.64	4.35	0.42	0.52	3.33
Linear KED	1.8	1.07	0.34	0.57	4.80	0.43	0.71	3.29
Linear KED (Cs=Cr=1; non-recalibrated model)	1	1	-0.08	0.48	6.15	0.49	0.62	3.11
Linear KED (Cs=Cr=1; recalibrated model)	1	1	0.04	0.45	5.82	0.47	0.60	3.18

359

360

361

362

363

364

365

366

367

368

369

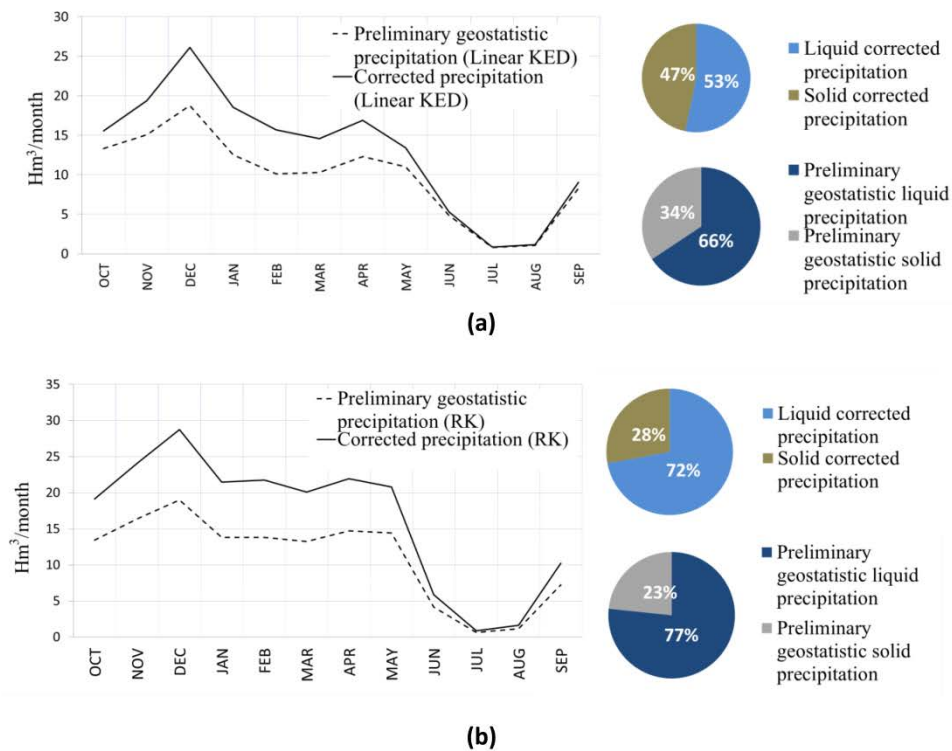
370 **Table 2.** Calibrated parameters of the hybrid snow-Témez model (STM) with different
 371 approaches of climatic fields

Parameter	Description	Lower boundary ^a	Upper boundary ^a	Calibrated values	
				RK	Linear KED
H _{max}	maximum soil moisture capacity (mm)	40	300	102.84	50.04
Imax	maximum infiltration (mm)	20	1000	450	550
α1	discharge parameter of aquifer 1 (day ⁻¹)	0.0003	0.03	0.005	0.007
α2	discharge parameter of aquifer 2 (day ⁻¹)	0.0003	0.03	0.030	0.029
b	Distribution coefficient of aquifers	0	1	0.54	0.61
C	Threshold to generate runoff	0.10	1	0.10	0.10
H ₀	Initial soil moisture (mm)		> 0	1	0.01
Q _{1,0}	Initial groundwater flow of aquifer 1 (mm)		> 0	1	0.01
Q _{2,0}	Initial groundwater flow of aquifer 0 (mm)		> 0	1.02	0
T _{melt}	Snowmelt base temperature (°C)	-6.10	2.10	2.04	0
T _f	Refreezing base temperature (°C)	-5.00	-0.001	-1.22	-1.07
Kd1	Without rain	0.01	15	0.93	4.56
Kd2	With rain	0.01	15	1.69	1.11
e	Exponent of refreezing	0.001	1	1	1
Ret	Liquid water retention capacity	0.020	0.52	0.02	0.02
E	Ratio of the evapostublimation versus total ablation	0.10	0.50	0.10	0.10
T _{min}	Snowfall base temperature (°C)	-6.10	0.00	-0.80	0.19
T _{max}	Rainfall base temperature (°C)	-0.10	5	4.23	5.00
Cr	Rainfall correction coefficient	1.01	1.40	1.40	1.07
Cs	Snowfall correction coefficient	1.05	1.80	1.78	1.8

372 a. From literature (Estrela et al., 1999; Herrero and Polo, 2016; Irannezhad et al., 2015;
 373 Murillo and Navarro, 2011; Témez, 1977)
 374

375 In all the simulated cases the modified precipitation shows an important mean
 376 increment with respect to the mean historical values. On the left of Figure7, we can see
 377 the temporal distributions of original precipitation and corrected precipitation for each


378 experiments. The period with the greatest correction of precipitation goes from October
 379 to May, which includes the months with possible snowfall. During the summer months
 380 (from June to September) we obtained the smaller increment in the precipitation. In
 381 KED lineal and quadratic data, this correction becomes almost zero or completely zero
 382 in summer months, where there is only liquid precipitation. On the right of Figure 7, the
 383 pie charts show the proportion of solid and liquid precipitation. The percentage of solid
 384 precipitation is higher in the corrected models. These results show that the
 385 underestimation of the solid precipitation is greater than for the liquid.



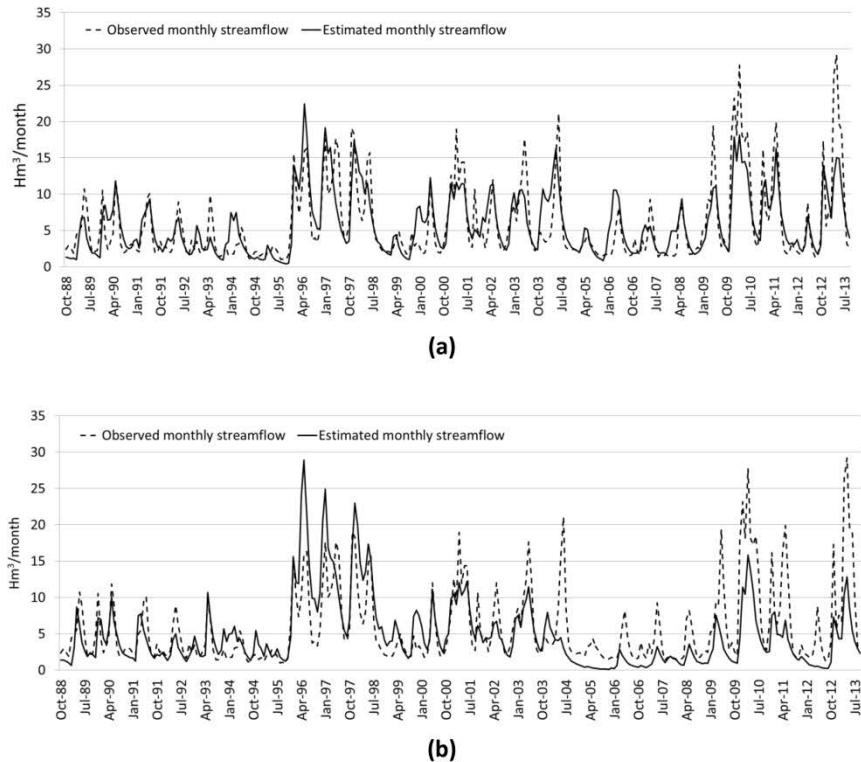
386 **Figure 7.** Estimated monthly mean precipitation and its annual distribution between solid
 387 and liquid phases (preliminary geostatistic fields vs corrected fields); (a) Linear KED model; (b)
 388 RK model.

389
 390
 391 The results obtained including a global correction factor to modify the intensity of
 392 the precipitation (for a global assessment of the under-catch) are significantly better

393 than those obtained without any correction. Simulated versus observed monthly
 394 discharge at the catchment outlet are shown in Figure 8a and 8b. There are three
 395 simulated time series in each figure. One corresponds to the simulation with the optimal
 396 values of C_r and C_s and the others correspond to the simulation with $C_r=C_s=1$ (no
 397 precipitation correction).



398 **Figure 8.** Estimated monthly mean streamflow (mean year) for the preliminary climatic
 399 fields vs corrected ones; (a) RK model; (b) Linear KED model.
 400



401 **Figure 9.** Estimated monthly streamflow for the period Oct 88-Sep2013 with the
 402 preliminary climatic fields and the corrected ones; (a) RK model; (b) Linear KED
 403 model.
 404

405 5. Analyses of results. Discussion


406 In accordance with the results of the modelling task performed the best combination of
 407 geostatistical approaches and STM hydrological models is obtained with the RK
 408 approach correcting the solid and liquid precipitation with the calibrated coefficients Cs
 409 and Cr respectively. The goodness of fit to the daily and monthly streamflow for the
 410 calibration and validation periods is better for the RK approach than the Linear KED
 411 according to the statistics R^2 , NSE and RMSE (Table 1.1 and 1.2). For the validation
 412 phase, the NSE values were 0.56 for daily scale and 0.68 for monthly scale. The R^2
 413 values were 0.58 for daily and 0.70 for monthly scale. The best results provided by the

414 STM model using the RK approach can also be observed graphically as discussed below.
415 In Figure 8a, the estimated monthly mean streamflow (mean year) was represented
416 showing THE RK a better approach in terms of mean water balance but also in terms of
417 temporal distribution. If we do not correct the precipitation fields we cannot approach
418 the maximum mean streamflows that take place during the late spring in the melting
419 period. Nevertheless, the models with the corrected field obtained for both geostatistical
420 approaches (RK and linear KED data) underestimate the peak of the hydrographs
421 (Figure 8a and 8b), they are clearly closer than the solutions obtained without correcting
422 the precipitation fields. In Figure 7a and 7b, we can see the existence of a wet season
423 that goes from autumn to the mid spring and a very dry season in the late spring and
424 summer. However, the Figure 8a and 8b show that the greatest flows of water in the
425 river occur at the end of the spring, specifically in May and June. This is due to the
426 snow dynamics that characterize this basin. The main drivers of the hydrological
427 dynamics of Sierra Nevada are snow occurrence and persistence. These processes buffer
428 the generation of runoff and maintain soil moisture, prolonging water flow in rivers well
429 past the wet season and ultimately determine habitat distribution (Herrero and Polo,
430 2016). The simulated streamflow was also analyzed in Figure 9a and 9b. Figure 9a
431 shows that the model with RK data reproduced the streamflow fairly well, being better at
432 reproducing low flows than maximum peaks. Contrary to this, the Figure 9b shows how
433 the model with Linear KED data is not so good neither in low nor high flows.

434 The optimal correction factor obtained for the solid and liquid precipitation are 1.78 and
435 1.40 respectively. Figure 8a and 8b show a poor simulation when the precipitation is not
436 corrected with large underestimation of streamflow in spring due to less amount of
437 snowfall in winter. In other studies, similar results were found, for example, Irannezhad
438 et al., (2015) optimized Cr at 1.02 and 1.39, and Cs at 1.05 and 1.35 for several

439 catchments. The corrected values of precipitation allow us to assess the corrected
440 precipitation pattern with the altitude (gradient with the altitude) in this alpine basin
441 (Figure 10). As we have pointed previously linear KED shows better results in the cross
442 validation experiment but RK provide a better approximation of the evolution of the
443 precipitation with the altitude observed with the experimental data (see Figure 5A).
444 With respect the corrected precipitation, for linear KED we obtain an increase of
445 precipitation especially in higher elevations due to the snowfall correction coefficient is
446 higher than rainfall correction coefficient (1.80 vs 1.07 respectively). Nevertheless, the
447 approximation obtained for the streamflow when using the KED lineal values as inputs
448 of the STM model is significantly worse than the one obtained with the RK values.
449 However for the RK approach the difference between these coefficients is less
450 important, 1.78 for snowfall and 1.40 for rainfall. They reduce the negative gradient of
451 precipitation initially predicted by the RK for altitude higher than 1000 m, due the
452 inversion of gradient phenomenon described in Collados-Lara et al. (2018). In that
453 research work a preliminary correction of the experimental data in the Alto-Genil basin
454 was performed by applying an experimental correction functions proposed by Buisan et
455 al. (2017) for some Spanish Mountain Ranges. The correction functions was applied to
456 the experimental data above a threshold elevation which was estimated as the median
457 (percentile 50) of the snowline elevation for each month of the snow season
458 (approximately 2000 meters). However they obtained modification of the estimations
459 below this threshold due to the spatial correlations of the estimations. For the Canales
460 basin they obtained mean correction coefficient of 1.17 and 1.09 for linear KED and RK
461 respectively if the elevation is below 2000 meters and 1.29 and 1.28 for linear KED
462 and RK respectively if elevation is above 2000 meters. These values are lower than the

463 obtained in this study. Nevertheless, the correction functions were obtained for other
 464 mountain ranges, and there is not any specifically available for our case study.



465 **Figure 10.** Corrected mean daily precipitation depending on the elevation in Canales
 466 Basin. (corrected fields vs origination data).

467 **6. Limitations and future reserchs**

- 468 - In this preliminary approach we assumed an invariant (in space and time) value
 469 of the undercatch (correction factor) of solid and liquid precipitation. In the
 470 future other approximations, for example correctiona values proportional to
 471 wind field intensity, could be explored
- 472 - The available climatic and streamflow data are quite limited in space and time in
 473 our case study.
- 474 - Although the snow model is distributed a lumped Hydrological balance model
 475 (Temez model) has been employed to simulate streamflow. Other experiments
 476 with ditributed Hydrological models could be performed.
- 477 - A hybrid degree day method is employed to approach melting processess within
 478 the snow model. Although it is not an energy balance approach it considers in a

479 simplified way the influence of some key variables related with the energy
480 balance.

481 - The model has been calibrated trying to minimize differences respect to natural
482 streamflow observations. A multicriteria calibration could be explored in the
483 future considering also other Hydrological variables, as the snow cover area
484 evolution.

485 **7. Conclusions**

486 In this work we propose a methodology to combine in an optimal way different
487 geostatistic approaches and a conceptual hydrological model in order to minimize
488 differences between estimated and historical natural stream-flow. It allows to perform a
489 preliminary assessment of global under-catch in alpine basins. Applying the proposed
490 method, we can also analyse the precipitation pattern within the basin in terms of
491 distribution between solid and liquid phase and spatial gradient with the elevation. It has
492 been applied to the Canales Basin, in Sierra Nevada (South Spain). The results show
493 that the historical stream-flow series can only be properly approached when we assume
494 very significant under-catch of precipitation (1,4 and 1,78 respectively for the liquid and
495 solid precipitation). This is the only way to approach the historical mean yearly stream-
496 flow including the snow peak due to the snow melting process. Correcting the under-
497 catch of precipitation with these factors the modified precipitation fields would show an
498 important reduction of the negative gradient of precipitation initially predicted by the
499 RK approach. Taking into account these results, the inversion of gradient phenomenon
500 described in Collados-Lara et al. (2018) for the Alto Genil Basin, which includes the
501 Canales Sub-basin, would be significantly smaller that the values predicted with the
502 non-corrected measurements in the gauges.

503 **References**

- 504 Adam, J.C., Lettenmaier, D.P., 2003. Adjustment of global gridded precipitation for
505 systematic bias. *Geophys. Res.* 108 (D9).
506
- 507 Akanegbu, J. O., Marttila, H., Ronkanen, A-K., Kløve, B., 2017. *J. Hydrol.* 545, 182-
508 196
509
- 510 Alter, J. C., 1937. Shielded storage precipitation gages. *Mon. Weather Rev.* 65(7), 262-
511 265.
512
- 513 Bartolini, E., Allamano, P., Laio, F., Claps, P., 2011. Runoff regime estimation at high-
514 elevation sites: a parsimonious water balance approach, *Hydrol. Earth Syst. Sc.* 15,
515 1661-1673.
516
- 517 Bejarano, M.D., Marchamalo, M., de Jalón, D.G., del Tánago, M.G., 2010. Flow regime
518 patterns and their controlling factors in the Ebro basin (Spain). *J. Hydrol.* 385(1), 323–
519 335.
520
- 521 Benning, J., Yang, D., 2005. Adjustment of daily precipitation data at Barrow and
522 Nome Alaska for 1995-2001. *Arct. Antarct. Alp. Res.* 37 (3), 276-283.
523
- 524 Bruland, O., Maréchal, D., Sand, K., Killingtveit, A., 2001. Energy and water balance
525 studies of a snow cover during snowmelt period at a high arctic site. *Theor. Appl.*
526 *Climatol.* 70, 53–63.
527
- 528 Buisán, S. T., Earle, M. E., Collado, J. L., Kochendorfer, J., Alastrué, J., Wolff, M., ...,
529 López-Moreno, J. I., 2017. Assessment of snowfall accumulation underestimation by
530 tipping bucket gauges in the Spanish operational network. *Atmos. Meas. Tech.* 10(3),
531 1079-1091.
532
- 533 CEDEX (Centre for Public Works Studies and Experimentation), 2018. Anuario de
534 Aforos (In Spanish). Available online: [http://ceh-
535 flumen64.cedex.es/anuarioaforos/default.asp](http://ceh-flumen64.cedex.es/anuarioaforos/default.asp) (accessed on 8 February 2018).
536
- 537 Chiles JP, Delfiner P., 1999. *Geostatistics: Modelling Spatial Uncertainty*. Wiley, New
538 York.
539
- 540 Collados-Lara, A.J., Pardo-Igúzquiza, E., Pulido-Velazquez, D., 2017. Spatiotemporal
541 estimation of snow depth using point data from snow stakes, digital terrain models, and
542 satellite data. *Hydrol. Process.* 31, 1966–1982.
543
- 544 Collados-Lara, A.J., Pardo-Iguzquiza, E., Pulido-Velazquez, D., 2018. Precipitation
545 fields in an alpine Mediterranean catchment. Inversion of precipitation gradient with
546 elevation or undercatch of snowfall?. *Int. J. Climatol.* DOI:10.1002/joc.5517.
547
- 548 Duan, Q., Sorooshian, S., Gupta, V. K., 1994. Optimal use of the SCEUA global
549 optimization method for calibrating watershed models, *J. Hydrol.* 158, 265–284.
550

- 551 Escriva-Bou, A., Pulido-Velazquez, M., Pulido-Velazquez, D., 2016. The Economic
552 Value of Adaptive Strategies to Global Change for Water Management in Spain's Jucar
553 Basin. *J. Water Res. Plan. Man.* 143(5), 04017005.
554
- 555 Estrela, T., Cabezas Calvo-Rubio, F., Estrada-Lorenzo, F., 1999. La evaluación de los
556 recursos hídricos en el Libro Blanco del Agua en España. *Ingeniería del agua*, [S.l.], v.
557 6, n. 2, jun. 1999. ISSN 1886-4996. <https://doi.org/10.4995/ia.1999.2781>.
558
- 559 Estrela, T., Quintas, L., 1996. A distributed hydrological model for water resources
560 assessment in large basins. In *Proceedings of 1st International Conference on Rivertech*,
561 Vol. 96, 861-868.
562
- 563 Fekete, B. M., Vörösmarty, C. J., Roads, J. O., Willmott, J. C., 2004. Uncertainties in
564 Precipitation and Their Impacts on Runoff Estimates. *J. Climate.* 17(2), 294-304.
565
- 566 Foster, J. L., Hall, D. K., Eylander, J. B., Riggs, G. A., Nghiem, S. V., Tedesco, M., ... ,
567 Choudhury, B., 2011. A blended global snow product using visible, passive microwave
568 and scatterometer satellite data. *Int. J. Remote Sens.* 32(5), 1371-1395.
569
- 570 Goodison, B., Louie, P., Yang, D., 1998. WMO solid precipitation measurement
571 intercomparison final report. WMO Tech. Document 872, World Meteorol. Organ.,
572 Geneva, Switzerland.
573
- 574 Groisman, P. Y., Koknaeva, V. V., Belokrylova, T. A., Karl, T. R., 1991. Overcoming
575 Biases of Precipitation Measurements: A History of the USSR Experience. *Bull. Am.*
576 *Meteorol. Soc.* 72 (11), 1725-1732.
577
- 578 Groisman, P.Y., Legates, D.R., 1994. The accuracy of United States precipitation data.
579 *Bull. Am. Meteorol. Soc.* 75, 215-227.
580
- 581 Gupta, V.K., Sorooshian, S., 1985. The Automatic Calibration of Conceptual
582 Catchment Models Using Derivative-Based Optimization Algorithms. *Water Resour.*
583 *Res.* 21, 473-485.
584
- 585 Herrero, J., Polo, M. J., 2016. Evapsublimation from the snow in the Mediterranean
586 mountains of Sierra Nevada (Spain). *Cryosphere.* 10, 2981-2998.
587
- 588 Hock, R., 2003. Temperature index melt modelling in mountain areas. *J. Hydrol.* 282,
589 104-115
590
- 591 Irannezhad, M., Ronkanen A. K., Kløve, B., 2015. Effects of climate variability and
592 change on snowpack hydrological processes in Finland. *Cold Reg. Sci. Technol.* 118,
593 14-29
594
- 595 Jevons, W. S., 1861. On the deficiency of rain in an elevated raingauge as caused by
596 wind. *Edinburgh & Dublin Philosophical Magazine.* 22 421-433.
597
- 598 Jódar, J., Cabrera, J. A., Martos-Rosillo, S., Ruiz-Constán, A., González-Ramón, A.,
599 Lambán, L. J., ... & Custodio, E., (2017). Groundwater discharge in high-mountain

- 600 watersheds: A valuable resource for downstream semi-arid zones. The case of the
601 Bérchules River in Sierra Nevada (Southern Spain). *Sci. Total Environ.* 593, 760-772.
602
- 603 Kuusisto, E., 1984. Snow accumulation and snowmelt in Finland. Publication of Water
604 Research Institute. National Boards of Waters, Helsinki.
605
- 606 Legates, D. R., 1987. A climatology of global precipitation. *Publ. in Climatology.* 40(1),
607 85.
608
- 609 Li, H., Beldring, S., Xu, C.Y., Huss, M., Melvold, K., Jain, S.K., 2015. Integrating a
610 glacier retreat model into a hydrological model – Case studies of three glacierised
611 catchments in Norway and Himalayan region. *J. Hydrol.* 527, 656-667.
612
- 613 Lindström G, Johansson B, Persson M, Gardelin M, Bergström S., 1997. Development
614 and test of the distributed HBV-96 hydrological model. *J. Hydrol.* 201, 272–288.
615
- 616 Martinec, J., Rango, A., Roberts, R., 2008. Snowmelt Runoff Model SRM User's
617 Manual. New Mexico State University, 178 pp.
618
- 619 Matheron G., 1963. Principles of Geostatistics. *Econ. Geol.* 58, 1246–1266.
620
- 621 Murillo, J. M., Navarro, J. A., 2011. Aplicación del modelo de Témez a la
622 determinación de la aportación superficial y subterránea del sistema hidrológico
623 Cornisa-Vega de Granada para su implementación en un modelo de uso conjunto.
624 *Boletín Geológico y Minero.* 122 (3), 363-388. ISSN: 0366-0176.
625
- 626 Nash, J., Sutcliffe, J., 1970. River flow forecasting through conceptual models Part I-A
627 discussion of principles. *J. Hydrol.* 10, 282–290.
628
- 629 Nelder, J. A., Mead, R., 1965. A simplex method for function minimization. *Computer*
630 *J.* 7(4), 308-313.
631
- 632 Nitu, R., 2013. Cold as SPICE: Determining the best way to measure snowfall.
633 *Meteorological Technology International.* 148-150.
634
- 635 Orozco-Medina, I., 2014. Modelación parsimoniosa y espacialmente distribuida de los
636 procesos de acumulación y fusión de nieve. Tesis doctoral. UPV, Valencia.
637
- 638 Pardo-Igúzquiza, E., Collados-Lara, A. J., Pulido-Velazquez, D., 2017. Estimation of
639 the spatiotemporal dynamics of snow covered area by using cellular automata models. *J.*
640 *Hydrol.* 550, 230-238.
641
- 642 Rasmussen, R., Baker, B., Kochendorfer, J., Meyers, T., Landolt, S., Fischer, A. P.,
643 Black, J., Thériault, J., Kucera, P., Gochis, D., Smith, C., Nitu, R., Hall, M., Cristanelli,
644 S., Gutmann, E., 2012. How well are we measuring snow?: the NOAA/FAA/ NCAR
645 winter precipitation test. *Bull. Am. Meteorol. Soc.* 93, 811–829.
646
- 647 Richer, E.E., Kampf, S.K., Fassnacht, S.R., Moore, C.C., 2013. Spatiotemporal index
648 for analyzing controls on snow climatology: application in the Colorado Front Range.
649 *Phys. Geogr.* 342, 85-107.

- 650
651 Rosenbrock, H., 1960. An automatic method for finding the greatest or least value of a
652 function. *Computer J.* 3(3), 175-184.
653
654 Sensoy, A., Uysal, G., 2012. The Value of Snow Depletion Forecasting Methods
655 Towards Operational Snowmelt Runoff Estimation Using MODIS and Numerical
656 Weather Prediction Data. *Water Resour. Manag.* 26(12), 3415-3440.
657
658 Sevruk, B., 1981. Methodical investigation of systematic error of Hellmann rain gauges
659 in the summer season in Switzerland (in German). *Trans. Versuchsanstalt für*
660 *Wasserbau, Hydrologie und Glaziologie, ETH. Zürich, Mitt. No. 52, 297 pp.*
661
662 Sevruk, B., 1982. Methods of correction for systematic error in point precipitation
663 measurement for operational use. *WMO Operational Hydrology Report No. 21,*
664 *Geneva, Switzerland.*
665
666 Sevruk, B., Hamon, W. R., 1984. International comparison of national precipitation
667 gauges with a reference pit gauge, *WMO Instrum. Obs. Methods Rep. 17, 111 pp.,*
668 *World Meteorol. Organ., Geneva, 1984.*
669
670 Sevruk, B., Ondrás, M., Chvíla, B., 2009. The WMO precipitation measurement
671 intercomparisons. *Atmos. Res.* 92, 376-380.
672
673 Sexstone GA, Fassnacht SR., 2014. What drives basin scale spatial variability of
674 snowpack properties in northern Colorado?. *Cryosphere.* 82, 329-344.
675
676 Shrestha, M., Wang, L., Koike, T., Tsutsui, H., Xue, Y., Hirabayashi, Y., 2014.
677 Correcting basin-scale snowfall in a mountainous basin using a distributed snowmelt
678 model and remote-sensing data. *Hydrol. Earth Syst. Sc.* 18, 747-761.
679
680 Smith, M., Koren, V., Zhang, Z., Moreda, F., Cui, Z., Cosgrove, B., ... , Anderson, E.,
681 2013. The distributed model intercomparison project–Phase 2: Experiment design and
682 summary results of the western basin experiments. *J. Hydrol.* 507, 300-329.
683
684 Stisen, S., Højberg, A. L., Trolborg, L., Refsgaard, J. C., Christensen, B. S. B., Olsen,
685 M., Henriksen, H. J., 2012. On the importance of appropriate precipitation gauge catch
686 correction for hydrological modelling at mid to high latitudes. *Hydrol. Earth Syst. Sc.*
687 16(11), 4157-4176.
688
689 Symons, G.J., 1864. Rain gauges and hints on observing them. *Br. Rainfall.* 8–13.
690
691 Temez, J. R., 1977. Modelo matemático de transformación precipitación aportación,
692 ASINEL. Asociación de Investigación Industrial Eléctrica, Madrid, Spain.
693
694 Tian, X., Dai, A., Yang, D., Xie, Z., 2007. Effects of precipitation-bias corrections on
695 surface hydrology over northern latitudes. *J. Geophys. Res-Atmos.* 112 (D14).
696
697 Valery, A., Andréassian, V., Perrin, C., 2009. Inverting the hydrological cycle: when
698 streamflow measurements help assess altitudinal precipitation gradients in mountain
699 areas. *IAHS Publ.* 333, 281-285.

- 700
701 Wilson, W. T., 1954. Analysis of winter precipitation observations in the cooperative
702 snow investigations. *Mon. Weather Rev.* 82, 183-195.
703
704 Wolff, M. A., Isaksen, K., Petersen-Øverleir, A., Ødemark, K., Reitan, T., Brækkan,
705 R., 2015. Derivation of a new continuous adjustment function for correcting wind-
706 induced loss of solid precipitation: results of a Norwegian field study. *Hydrol. Earth*
707 *Syst. Sc.* 19(2), 951-967.
708
709 Wu, Q., Liu, S., Cai, Y., Li, X., Jiang, Y., 2017. Improvement of hydrological model
710 calibration by selecting multiple parameter ranges. *Hydrol. Earth Syst. Sc.* 21, 393-407.
711
712 Yang, D., Goodison, B. E., Metcalfe, J. R., Golubev, V. S., Elomaa, E., Gunther, T.,
713 Bates, R., Pangburn, T., Hanson, C. L., Emerson, D., Copaciu, V., Milkovic J., 1995.
714 Accuracy of Tretyakov precipitation gauge: Result of WMO intercomparison. *Hydrol.*
715 *Process.* 9 (8), 877-895.
716
717 Zhang, S., Shi, J., 2011. A Microwave Wetland Surface Emissivity Calibration Scheme
718 Using SCE-UA Algorithm and AMSR-E Brightness Temperature Data. *Procedia*
719 *Environ. Sci.* 10, 2731-2739.

4.5 SÍNTESIS DE RESULTADOS Y DISCUSIÓN

4.5.1 Simulación hidrológica con los modelos SWAT y RNA

Los modelos SWAT y las RNAs para simular los caudales en las cuencas del río Ladra (LRB) y en la cuenca de cabecera del río Segura (HSRB) se construyeron utilizando información de libre acceso. Los datos de caudales diarios de LRB se obtuvieron del Anuario de Aforos del CEDEX, con registros disponibles a partir de 1971. Los datos de caudales diarios para la cuenca HSRB, disponibles desde 1987, se descargaron de la web de la Confederación Hidrográfica del Río Segura. La base de datos climáticos empleada para esta tarea fue la de SPAIN02 (más detalles en Herrera et al., (2012)), con datos diarios de precipitación y temperatura desde 1950 a 2007 con una malla de 20x20 km. Los DEMs se obtuvieron del Instituto Geográfico Nacional de España, con una resolución de 25 m. Los datos del suelo se obtuvieron de la base de datos *Harmonized World Soil* (Nachtergaele et al., 2010) y del proyecto *Corine Land Cover*.

4.5.1.1 Análisis de sensibilidad, calibración y validación de los modelos SWAT

Para la simulación del modelo SWAT se utilizaron los datos de precipitación diaria (mm) y los datos de temperatura máxima y mínima (°C) de 1971 a 2007 en LRB y de 1987 a 2007 en la cuenca HSRB. La humedad relativa, la radiación solar y la velocidad del viento no estaban disponibles en las áreas de estudio, por lo que la evapotranspiración potencial se calculó utilizando el método Hargreaves (Hargreaves et al., 1985) porque solo requiere temperaturas máximas y mínimas diarias. En SWAT, tras la combinación de los DEM, mapas de suelo y mapas de usos del suelo, la cuenca LRB quedó dividida en 11 subcuencas y 124 HRUs, mientras que la cuenca HSRB en 3 subcuencas y 21 HRUs.

El análisis de sensibilidad y la calibración de los parámetros del modelo SWAT se llevaron a cabo automáticamente en SWAT-CUP usando el algoritmo SUFI-2. En primer lugar, se realizaron 500 ejecuciones de los modelos para obtener las sensibilidades, y se identificaron los parámetros más sensibles para cada cuenca. El efecto de los parámetros en el caudal simulado se evaluó empleando el estadístico *p-value* que determina la importancia de la sensibilidad, y *t-stat* que proporcionan una medida de sensibilidad. El ranking de los

parámetros más sensibles para este estudio (Tabla 4) están respaldados por el trabajo de Raposo et al., (2013) en la cuenca LRB y por el trabajo de Senent-Aparicio et al., (2017) en la cuenca HSRB. Algunos de los parámetros más sensibles son comunes para ambas cuencas con un orden similar de sensibilidad, como por ejemplo ALPHA_BF, CH_N1, CH_N2, SOL_K, CN2 y GWQMN.

Tabla 4. Análisis de sensibilidad de los parámetros del modelo SWAT para las cuencas LRB y HSRB.

Parámetro	Definición	LRB			HSRB		
		<i>t</i> -stat	<i>p</i> -value	Rank	<i>t</i> -stat	<i>p</i> -value	Rank
ALPHA_BF	Coefficiente de agotamiento del flujo base (días ⁻¹)	21.87	0.00	1	0.95	0.34	14
CH_N1	Número de Manning en los canales tributarios	12.73	0.00	2	9.23	0.00	1
OV_N	Número de Manning para el flujo terrestre	5.98	0.00	3	1.23	0.22	12
GW_DELAY	Tiempo de retardo del agua subterránea (días)	-5.45	0.00	4	-0.91	0.36	15
CH_N2	Número de Manning para el canal principal	2.59	0.01	5	2.08	0.04	7
SOL_K	Conductividad hidráulica saturada (mm/h)	2.48	0.01	6	2.09	0.04	6
CN2	SCS número de curva	2.42	0.02	7	-8.09	0.00	2
GWQMN	Profundidad umbral de agua en el acuífero superficial para que se produzca flujo de retorno (mm)	1.97	0.05	8	2.01	0.04	9
CH_K1	Conductividad hidráulica efectiva en canales tributarios (mm/h)	-1.78	0.08	9	3.90	0.00	4

RCHRG_DP	Factor de percolación al acuífero profundo	-1.77	0.08	10	-2.05	0.04	8
LAT_TTIME	Tiempo de viaje del flujo lateral (días)	-1.49	0.14	11	-2.16	0.03	5
SOL_AWC	Capacidad de agua disponible de la capa del suelo (mm H ₂ O/mm suelo)	1.34	0.18	12	5.39	0.00	3
BIOMIX	Eficiencia de la mezcla biológica	1.23	0.22	13	0.80	0.42	16
SLSUBBSN	Longitud promedio de la pendiente (m)	1.21	0.23	14	0.25	0.80	20
GW_REVAP	Coficiente "revaporación" del flujo subterráneo	1.11	0.27	15	1.41	0.16	10
SURLAG	Coficiente de retraso de la escorrentía superficial	1.01	0.31	16	0.37	0.71	19
REVAPMN	Umbral de profundidad del agua en el acuífero superficial para "revaporación" a la capa de suelo o percolación al acuífero profundo (mm)	0.93	0.36	17	1.20	0.23	13
CANMX	Capacidad máxima de interceptación vegetal (mm)	0.47	0.64	18	1.26	0.21	11
ESCO	Factor de compensación de la evaporación del suelo	-0.20	0.84	19	-0.42	0.67	18
EPCO	Factor de compensación de la captación de las plantas	0.01	0.99	20	0.69	0.49	17

Posteriormente al análisis de la sensibilidad global, se seleccionaron los parámetros más sensibles para cada cuenca y se realizaron dos iteraciones de 1500

simulaciones según lo recomendado por Yang, Reichert, Abbaspour, Xia, & Yang (2008), reajustando los parámetros después de la segunda iteración. Los parámetros seleccionados y ajustados se recogen en la Tabla 5. Estos parámetros también fueron seleccionados como los más relevantes en otras investigaciones (Kim et al., 2015; Molina-Navarro, Martínez-Pérez, Sastre-Merlín, & Bienes-Allas, 2014; Raposo et al., 2013; Senent-Aparicio et al., 2017).

Tabla 5. Parámetros usados en la calibración del modelo SWAT en las cuencas LRB y HSRB.

Parámetro	Rango	Valor ajustado	
		LRB	HSRB
GWQMN	0–5000	82.50	642.17
GW_DELAY	0–500	2.52	1.38
RCHRG_DP	0–1	0.01	0.70
ALPHA_BF	0–1	0.09	0.20
GW_REVAP	0.02–0.2	-	0.14
REVAPMN	0–1000	-	65.59
CH_K1	0–300	6.98	230.73
CH_N2	0.01–0.3	0.13	0.30
CH_N1	0.01–0.3	0.19	0.12
CN2	±20%	-1.35%	-3.75%
SOL_K	±20%	+12.01%	-12.04%
SOL_AWC	0–1	-1.29%	-5.51%
ESCO	0.1–1	0.77	0.39
SLSUBBSN	±20%	-0.57%	-
OV_N	0.01–0.8	0.69	-
LAT_TTIME	0–180	3.95	6.79
BIOMIX	0–1	0.94	-
CANMX	0–100	-	4.71

Los valores ajustados de estos parámetros reflejan las diferentes características climáticas de las dos cuencas. En la cuenca HSRB, los parámetros del agua subterránea (GWQMN, GW_DELAY, RCHRG_DP, ALPHA_BF y GW_REVAP) fueron significativos, tal como se esperaba en una cuenca mediterránea donde los acuíferos son relevantes (Conan et al., 2003; Molina-Navarro et al., 2014). Un valor alto del factor de percolación al acuífero profundo

(RCHRG_DP) y un tiempo de retardo para la recarga subterránea (GW_DELAY), reflejan la geología altamente permeable de HSRB. Por el contrario, no hay ningún acuífero relevante presente en LRB, donde RCHRG_DP resultó muy bajo. En ambas cuencas, los valores bajos de ALPHA_BF indican una respuesta subterránea lenta (Arnold et al., 2012). El bajo valor de CH_K1 en LRB indica una tasa de pérdida moderada para suelos con alto contenido de limo-arcilla, mientras que un valor alto en HSRB reflejó una tasa de pérdida muy alta para grava muy limpia y arena de gran granulometría (Arnold et al., 2012). Otra gran diferencia entre las dos cuencas es el factor de compensación de la evaporación del suelo (ESCO). El ESCO fue más alto en el LRB, con un clima atlántico, que en HSRB con un clima mediterráneo, donde la evapotranspiración tiene una mayor relevancia (Senent-Aparicio et al., 2017). Cuando el valor de ESCO disminuye, la capacidad del modelo para extraer la demanda de evaporación de las capas inferiores del suelo aumenta (Neitsch et al., 2011). El tiempo de viaje de flujo lateral (LAT_TTIME) en el LRB fue muy similar al utilizado por Raposo et al., (2013) en cuencas cercanas donde una porción significativa del agua subterránea fluye lateralmente como interflujo (Soriano & Samper, 2000).

4.5.1.2 Selección de inputs, entrenamiento y validación de las RNAs

Para el entrenamiento de las RNAs se ha utilizado el algoritmo de *backpropagation* de Levenberg-Marquardt (LM). La superioridad del algoritmo de LM (Levenberg, 1944; Marquardt, 1963) frente a otros ha quedado demostrada en varios estudios de predicción de caudales (p.e., Kişi, 2007; Nayebi, Khalili, Amin, & Zand-Parsa, 2006), demostrando un mejor rendimiento (menor error estimado) y una mayor velocidad. Para evitar un sobreajuste, se realizó una validación cruzada, dividiendo los conjuntos de datos en cinco subconjuntos: cuatro subconjuntos se utilizaron para entrenar, y el subconjunto restante se utilizó para testear el modelo. Estudios encontrados en la literatura utilizan el análisis de correlación de las variables para determinar la dependencia entre la variable dependiente (el caudal diario) y las variables independientes (variables climáticas de los días previos (Amirhossien et al., 2015; Shiau & Hsu, 2016; Wang et al., 2014). La determinación de las variables de entrada tiene una influencia significativa en el caudal simulado. Los datos de precipitación y temperatura de la cuenca utilizados por las RNAs se obtuvieron utilizando el método de

Thiessen, en el que los valores climáticos están basados en un promedio ponderado de la contribución de la celda en el área. Después de revisar otras investigaciones (Demirel et al., 2009; Kim et al., 2015; Yaseen, El-Shafie, Jaafar, Afan, & Sayl, 2015) se seleccionaron las siguientes variables como entradas a los modelos de RNAs para estimar el caudal diario (Q_t): precipitación diaria (P_t), temperatura diaria (T_t), precipitación de los n días previos (P_{t-n}), precipitación total de los n días anteriores (R_n) y temperatura media durante los n días previos (T_{m_n}). En este estudio, las demoras (time-lags) o días anteriores a considerar como más adecuados de las variables climáticas, se determinaron mediante un análisis de correlación cruzada. Así se determinaron las relaciones temporales entre las variables de entrada y el caudal. Como se muestra en la Figura 13a, el caudal está fuertemente correlacionado de forma positiva con la precipitación diaria del día actual t (P_t) y con la precipitación diaria de los días previos, hasta $t-4$ para LRB y hasta $t-2$ en HSRB.

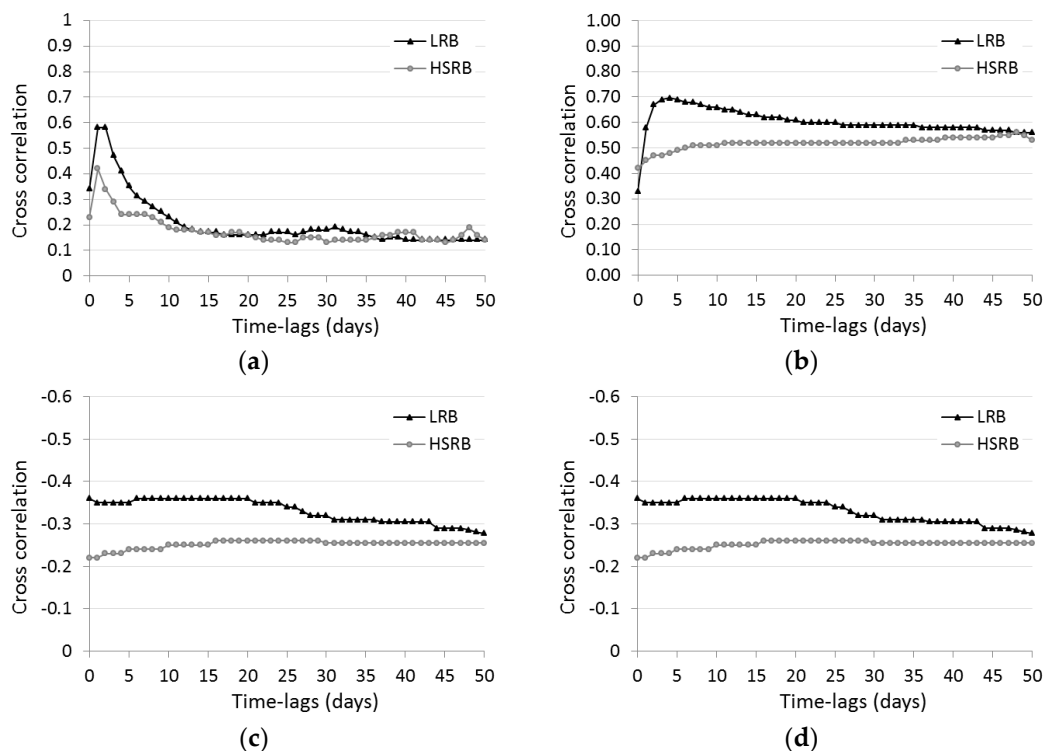


Figura 13. Análisis de correlación cruzada para LRB y HSRB entre el caudal diario y (a) la precipitación diaria; (b) la precipitación total de los n días precedentes; (c) temperatura diaria; (d) temperatura media de los n días precedentes.

El caudal también está fuertemente correlacionado con la lluvia diaria acumulada (Figura 13b); la mayor correlación se da para la precipitación acumulada en 4 días para la cuenca LRB y para la acumulada en 48 días en la cuenca HSRB, lo que refleja la poca y la gran importancia del agua subterránea, respectivamente. Con respecto a la temperatura diaria, existen correlaciones negativas moderadas con el caudal diario en ambas cuencas (Figura 13c y 13d). Tras múltiples pruebas, se seleccionaron cuatro combinaciones de inputs para cada cuenca (Tabla 6).

Tabla 6. Escenarios de predicción con las diferentes combinaciones de inputs consideradas para las RNAs en cada cuenca.

Cuenca	Escenario	Combinación de inputs	Output
LRB	1	$P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, T_t$	Q_t
	2	P_t, R_4, T_t, T_{m30}	Q_t
	3	$P_t, P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, R_4, T_t$	Q_t
	4	$P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, R_4$	Q_t
HSRB	1	$P_t, P_{t-1}, P_{t-2}, T_t$	Q_t
	2	$P_t, P_{t-1}, R_{48}, T_t$	Q_t
	3	P_t, P_{t-1}, R_{48}	Q_t
	4	P_{t-1}, R_{48}, T_{m30}	Q_t

Para la identificación de la estructura de la red, las RNAs se implementaron utilizando el software MATLAB® (versión 8.2.0.701 (R2013b), The MathWorks, Natick, MA, EE.UU.). Se utilizaron redes feed-forward multicapa o perceptrón multicapa (MLP). La cantidad de capas y neuronas ocultas se estableció mediante un procedimiento de prueba y error; se consideraron una o dos capas ocultas con un número de neuronas que variaba entre dos y diez. El número de neuronas en la capa de entrada es función del número de variables de entrada, es decir, del número de inputs en cada escenario, variando este número de 3 a 7. La Figura 14 muestra la estructura de RNA utilizada en este trabajo.




Figura 14. Estructura de la red MLP utilizada en esta investigación

Los diferentes escenarios definidos en la Tabla 6 fueron probados con el objetivo de determinar la mejor estructura de red y la mejor combinación de inputs. La Tabla 7 muestra los resultados de la mejor estructura de RNA encontrada para cada uno de los escenarios. Las medidas de ajuste mostradas son los valores promedio obtenidos en la validación cruzada de 5-fold.

Tabla 7. Mejor arquitectura de red neuronal y sus rendimientos medios obtenidos en la validación cruzada para cada escenario de predicción.

Cuenca	Escenario de predicción	Arquitectura de RNA (I-H-O) ¹	Entrenamiento			Validación		
			NSE	PBIAS (%)	RMSE	NSE	PBIAS (%)	RMSE
LRB	1	6-2-1	0.63	1.17	22.51	0.59	12.52	23.02
	2	4-2-1	0.52	0.62	24.75	0.52	1.67	24.85
	3	7-2-1	0.62	2.91	22.64	0.58	12.07	23.52
	4	5-2-1	0.56	0.71	24.45	0.53	7.26	24.65
HSRB	1	4-2-1	0.28	5.52	1.96	-0.15	29.85	1.90
	2	4-4-1	0.55	2.16	1.54	0.26	13.53	1.66
	3	3-4-1	0.56	6.85	1.51	0.32	12.02	1.57
	4	3-3-3-1	0.47	1.29	1.69	0.10	21.15	1.81

¹ I es el número de neuronas en la capa de entrada; H es el número de neuronas en la capas ocultas (una o dos capas ocultas); O es el número de neuronas en la capa de salida.

Los resultados que se muestran en la Tabla 7 indican cuatro estructuras de RNAs eficaces, con buenos rendimientos, para la cuenca LRB. El escenario 1 de LRB, con una combinación de seis neuronas en la capa de entrada (la precipitación de los días t , $t-1$, $t-2$, $t-3$ y $t-4$, y la temperatura del día t), una capa oculta con dos neuronas, y una neurona en la capa de salida (el caudal del día t), obtuvo el coeficiente de eficiencia de Nash-Sutcliffe (NSE) más alto y el error

cuadrático medio (RMSE) más bajo en la fase de entrenamiento y de validación. Para evaluar estas medidas de rendimiento, se siguieron los criterios propuestos por Kalin, Isik, Schoonover, & Lockaby (2010), quienes adaptaron los criterios mensuales propuestos por Moriasi et al. (2007) a una escala diaria. Estos criterios quedan recogidos en la Tabla 8. Además, como el estudio es un análisis exploratorio del poder de los modelos SWAT y RNAs para la simulación diaria de escorrentía, esto es una razón adicional para relajar los criterios de evaluación del rendimiento según la Sociedad Americana de Ingenieros Agrícolas y Biológicos (American Society of Agricultural and Biological Engineers [ASABE], 2017).

Tabla 8. Criterios de evaluación del modelo para escala diaria.

Clasificación del ajuste	NSE	PBIAS (%)
Muy bueno	$NSE \geq 0.7$	$ PBIAS \leq 25$
Bueno	$0.5 \leq NSE < 0.7$	$25 < PBIAS \leq 50$
Satisfactorio	$0.3 \leq NSE < 0.5$	$50 < PBIAS \leq 70$
Insatisfactorio	$NSE < 0.3$	$ PBIAS > 70$

De acuerdo con los criterios de la Tabla 8, el NSE y PBIAS del escenario 1 de LRB fueron buenos y muy buenos, respectivamente. Por lo tanto, el escenario 1 fue la arquitectura seleccionada para LRB. Sin embargo, el rendimiento de los diferentes modelos de RNAs para HSRB fueron peores en general, porque modelar la respuesta hidrológica de las regiones áridas y semiáridas, donde las tasas de evapotranspiración son altas y la precipitación es irregular y/o limitada, es especialmente complejo (Pérez-Sánchez, Senent-Aparicio, Segura-Méndez, & Pulido-Velazquez, 2017). El modelo seleccionado para HSRB fue el escenario 3, donde NSE y RMSE fueron mejores que los obtenidos en los otros escenarios propuestos. En este escenario 3, NSE se clasificó como satisfactorio y PBIAS como muy bueno. El resto de los escenarios se clasificaron como insatisfactorios según NSE. Por lo tanto, la configuración de RNA seleccionada para la cuenca HSRB fue de tres neuronas en la capa de entrada (la precipitación del día t y $t-1$, y la precipitación total de los 48 días anteriores), una capa oculta con cuatro neuronas, y una neurona en la capa de salida (el caudal del día t). En conclusión, la estructura seleccionada para ambas cuencas estaba formada por tres capas,

similar a la estructura seleccionada en otros estudios hidrológicos (p. e., Amirhossien et al., 2015; Kim et al., 2015).

4.5.1.3 Comparación del rendimiento de los modelos SWAT y RNA

La calibración de los modelos SWAT y el entrenamiento de las RNAs seleccionadas se realizaron utilizando los conjuntos de datos de calibración y de entrenamiento, 1971-1989 para la cuenca LRB y 1987-1997 para HSRB. Posteriormente, una vez calibrados los modelos, éstos fueron probados con los conjuntos de validación, 1990-2007 para LRB y 1998-2007 para HSRB.

La comparación del rendimiento de SWAT y RNA en la simulación de caudales para LRB y HSRB queda recogida en la Tabla 9, la cual muestra por separado los rendimientos en la fase de calibración/entrenamiento y los de validación.

Tabla 9. Rendimientos para los modelos SWAT y RNA.

Cuenca	Modelo	Calibración/Entrenamiento				Validación			
		NSE	PBIAS (%)	RMSE	R ²	NSE	PBIAS (%)	RMSE	R ²
LRB	SWAT	0.59	2.55	22.11	0.59	0.57	7.18	25.78	0.58
	ANN	0.64	2.03	20.81	0.63	0.59	12.94	25.39	0.61
HSRB	SWAT	0.52	4.37	1.76	0.53	0.48	8.74	1.45	0.49
	ANN	0.54	9.03	1.73	0.57	0.49	5.28	1.51	0.52

Los valores de NSE para ambos modelos se clasificaron como buenos según los criterios de la Tabla 8, para la fase de calibración y entrenamiento en LRB y en HSRB. Para la fase de validación, los valores de NSE quedaron comprendidos entre 0.5 y 0.7, y por lo tanto, se clasificaron como buenos para ambos modelos de la cuenca LRB. Los valores de NSE para la cuenca HSRB se clasificaron como satisfactorios para ambos modelos en calibración. Los valores del PBIAS fueron inferiores al 25%, por lo que los modelos se clasificaron como muy buenos en todos los casos. Los valores de RMSE para ambos modelos fueron similares. Los valores de NSE y R² obtenidos por el modelo de RNA fueron mejores que aquellos obtenidos en SWAT en ambas cuencas, y estos también fueron mejores en la fase de entrenamiento que los obtenidos en la fase de validación. Después de analizar estos resultados, se concluyó que tanto SWAT como ANN eran adecuados para simular caudales, pero se observó que cuanto más árida era la

cuenca, menores eran los rendimientos obtenidos en los modelos hidrológicos, conclusión similar a la llegada por Pérez-Sánchez et al. (2017) en su investigación.

Para una mejor comprensión de la diferencia entre ambos modelos, la Figura 15 muestra los resultados de los modelos SWAT y RNAs representados frente a los valores observados del caudal para los períodos de calibración/entrenamiento y validación con sus correspondientes coeficientes de determinación.

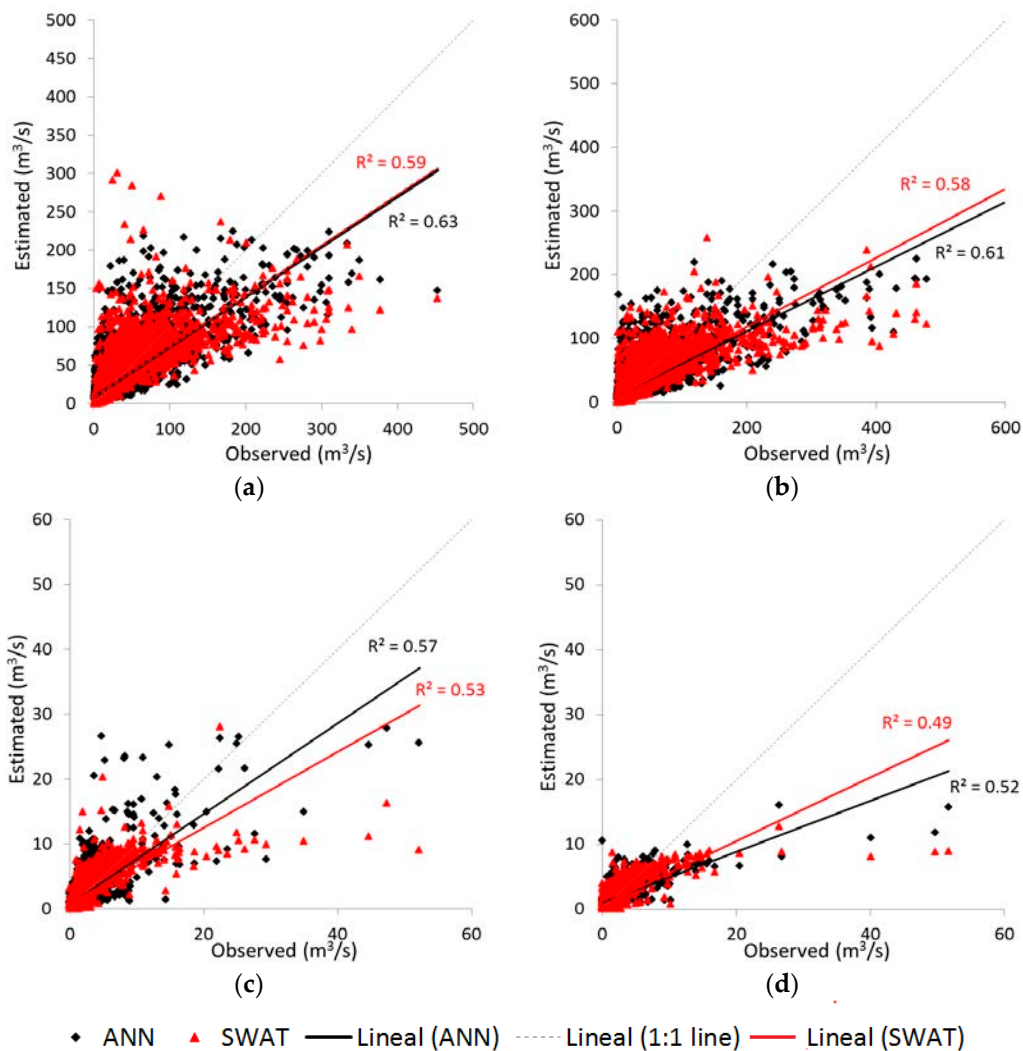


Figura 15. Diagrama de dispersión del caudal diario simulado frente al observado, en rojo los resultados de SWAT y en negro los resultados de la RNA (ANN, por sus siglas en inglés) (a) para el periodo de calibración de la cuenca LRB; (b) para el periodo de validación de la cuenca LRB; (c) para el periodo de calibración de la cuenca HSRB; (d) y para el periodo de validación de la cuenca HSBR.

En la Figura 15 se puede observar que el modelo SWAT obtuvo un rendimiento más pobre en la estimación de los valores grandes de caudal, mientras que el modelo de RNA obtuvo peores resultados al estimar los valores pequeños. En cada una de las figuras de la Figura 15, los puntos que corresponden a valores grandes de caudal se ubican a una distancia mayor de la línea 1:1 cuando los valores han sido estimados por SWAT. Por el contrario, los puntos relacionados con el caudal estimado con las RNAs están más alejados de la línea 1:1 cuando se trata de la estimación de valores pequeños.

Los hidrogramas de la Figura 16 muestran el ajuste obtenido, representando el caudal simulado frente al caudal observado en las cuencas estudiadas durante el período de validación (de 1995 a 1997 para el LRB, y de 2002 a 2004 para el HSRB).




Figura 16. Caudal diario simulado por SWAT (en rojo) y RNA (en negro) frente al caudal observado (en verde) en la fase de validación; el gráfico de barras en la parte superior es la precipitación diaria; (a) para la cuenca LRB; (b) para la cuenca HSRB.

Ambos modelos reprodujeron el caudal de forma adecuada en general. Sin embargo, ambos tendieron a subestimar los eventos de flujo máximo durante la fase de validación. Los modelos de RNAs fueron más sensibles a los eventos de precipitación que los modelos SWAT, y sus estimaciones se mantuvieron por encima de las obtenidas por SWAT.

De acuerdo con Chen & Chau (2016), los estadísticos NSE y RMSE escalan el error cuadrático medio de los modelos, por lo tanto, reflejan particularmente el rendimiento de los valores altos. Por lo que los criterios de evaluación anteriormente comentados y las representaciones gráficas de los datos estimados no pueden indicar el rendimiento general en los diferentes intervalos de caudal. Para abordar este problema, se determinaron diferentes rangos del caudal (de muy alto a muy bajo flujo) y se analizaron los resultados de forma gráfica mediante las curvas de duración del caudal (CDC) para la cuenca LRB y para la cuenca HSRB para los períodos de validación (Figura 17). La CDC para LRB muestra que la RNA se comportó mejor en caudales muy altos y SWAT fue mejor en caudales muy bajos. Los valores obtenidos por SWAT y por RNA fueron gráficamente similares para el resto de caudales en LRB. En cambio, para la cuenca HSRB, SWAT fue mejor solamente en los caudales muy bajos.

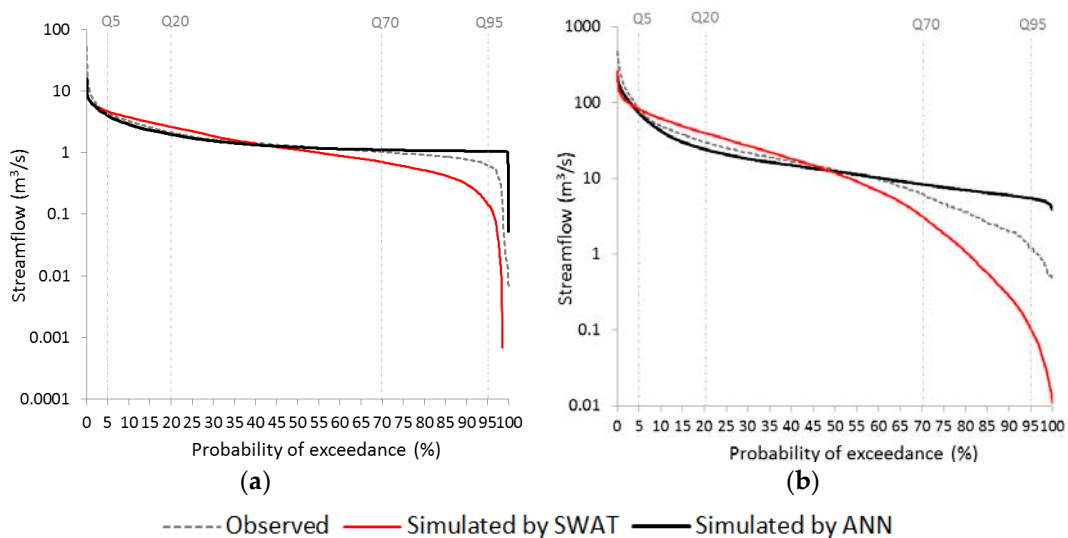


Figura 17. CDC del periodo de validación de la cuenca (a) LRB; (b) y HSRB.

Además de este análisis gráfico de los caudales, se realizó un análisis del rendimiento basado en RMSE en cada fase del hidrograma tal y como se refleja en la Tabla 10, donde los mejores resultados para cada cuenca se resaltan en negrita. Como era de esperar según los resultados analizados anteriormente, los picos altos se simulan mejor a expensas de los flujos bajos debido al hecho de que el RMSE está sesgado hacia valores altos. Los valores del RMSE vuelven a mostrar que el modelo SWAT fue mejor en la estimación de flujos muy bajos y que el modelo de RNA resultó mejor en la estimación de caudales muy altos para ambos casos de estudio.

Tabla 10. Valores del RMSE (m^3/s) de los modelos SWAT y RNA para cada fase del hidrograma.

Fases del hidrograma (Caudales)	Cuenca									
	Rango del caudal (m^3/s)	LRB				HSRB				
		Calibración		Validación		Rango del caudal (m^3/s)	Calibración		Validación	
		SWAT	ANN	SWAT	ANN		SWAT	ANN	SWAT	ANN
Muy altos	[82.8,478.2]	73.40	64.26	100.42	92.72	[4.5,51.7]	6.64	5.80	5.98	5.81
Altos	[30.3,82.8]	26.71	26.06	21.85	26.43	[2.1,4.5]	1.53	2.29	0.91	1.30
Medios	[6.2,30.3]	13.93	13.74	12.36	12.74	[1.0,2.1]	0.99	0.84	0.73	0.64
Bajos	[1.2,6.2]	5.17	8.97	6.79	10.10	[0.6,1.0]	0.54	0.58	0.53	0.48
Muy bajos	[0.4,1.2]	1.50	7.80	1.00	7.41	[0,0.60]	0.29	0.90	0.60	1.22

Resultados similares con respecto a la ineficiencia en la estimación de caudales altos del modelo SWAT se han obtenido en otros estudios (p. e., Demirel et al., 2009; Kim et al., 2015; Makwana & Tiwari, 2017), lo que sugiere que la ineficacia en obtener estos caudales altos podría ser causada por la formulación. Los resultados obtenidos muestran que el uso de modelos de RNAs puede ayudar a reducir el error en la estimación de los valores de caudales altos, aunque también estos se subestimaron. Una de las razones que dificulta la simulación de estos caudales altos es que los datos de estos caudales son escasos en los conjuntos de datos de entrenamiento, siendo los valores medios y bajos los más numerosos, tal y como se observa en la nube de puntos de los diagramas de dispersión de la Figura 15. Este problema de subestimación de los caudales altos en la aplicación de redes neuronales también ha sido reportado en los trabajos de Minns & Hall (1996) y Talebizadeh, Morid, Ayyoubzadeh, & Ghasemzadeh, (2010). Por otro lado, el modelo SWAT simuló los valores de caudales bajos mejor

que las RNAs. En general, el modelo de RNA tendió a sobreestimar los valores bajos de caudal. Esta incapacidad puede atribuirse a complejas relaciones no lineales que rigen el proceso de caudales bajos, a menudo relacionadas con el flujo base del agua subterránea, y el rendimiento de las RNAs puede verse deteriorado con el aumento de la no linealidad (Minns & Hall, 1996). Es bien conocido que los procesos de generación de caudales pueden ser bastante diferentes durante periodos de caudales altos, medios y bajos. El flujo base contribuye principalmente a eventos de bajo flujo, mientras que los episodios de tormentas con lluvia intensa da lugar a eventos de caudales altos (Wu, Chau, & Li, 2009).

Por lo tanto, es complicado que un único modelo de RNA pueda predecir satisfactoriamente los eventos de escorrentía alta y baja (Minns & Hall, 1996) y que el modelo SWAT pueda simular un caudal muy alto con la misma precisión con que simula los caudales bajos. En contraste con SWAT, una RNA puede obtener resultados mejores para valores muy altos pero no para los valores más bajos; estos resultados son similares a los obtenidos por Kim et al., (2015).

Estos resultados lleva a la conclusión de que el uso de estos modelos es adecuado para simular el flujo de una cuenca. Sin embargo, en el caso de estudios de eventos hidrológicos extremos (p. e., inundaciones), se recomienda utilizar un modelo de RNA para simular eventos de alto flujo. Y por el contrario, en los estudios de gestión hidrológica en los que los eventos de bajo flujo son más interesantes, la aplicación del modelo SWAT sería más adecuado.

En la aplicación de cualquier modelo también es importante tener en cuenta las desventajas de cada uno de ellos. En España, es relativamente más fácil obtener los datos necesarios para el modelo de RNA (como son los datos de caudales, de precipitación y de temperatura) a través de los recursos gubernamentales online, en comparación con la obtención de los datos necesarios para SWAT sobre las características físicas de las cuencas hidrográficas, como la humedad del suelo, infiltración, clases de suelos, nivel de agua subterránea y evaporación. Además, el tiempo consumido en la configuración y calibración de SWAT es mayor que el que se consume en la implementación de un modelo de RNA. Sin embargo, una RNA es una caja negra, y el balance de agua y sus componentes no se pueden obtener como sí que ocurre en SWAT. El uso de la precipitación y la temperatura como las únicas entradas de los modelos es una ventaja, pero por otro lado es una limitación de los modelos de RNAs puesto que

la relación precipitación-escorrentía también se ve afectada por otros parámetros físicos. La no consideración del uso de la tierra o de la gestión de la tierra en el modelo de RNA hace que el modelo SWAT sea más ventajoso si el objetivo del estudio fuera simular varios escenarios para analizar la respuesta de la cuenca (Amirhossien et al., 2015). Los resultados de este estudio sugieren, sin embargo, que el enfoque de los modelos de RNAs es eficiente en la simulación de procesos hidrológicos porque requiere muy pocas variables de entrada y recursos mínimos para implementarlo, y por lo tanto, es lo suficientemente prometedor.

4.5.2 Estimación del caudal máximo instantáneo utilizando técnicas de machine learning frente a fórmulas empíricas

Para el cálculo del caudal máximo instantáneo (Q_{ins}) a partir del máximo caudal diario (MQ_{md}) se utilizaron las fórmulas empíricas de Fuller, CEDEX, Sangal y Fill & Steiner, y la mejor de estas fórmulas para cada subcuenca estudiada fue analizada frente a dos técnicas de machine learning, RNA y ANFIS.

Como se muestra en la Tabla 11, para realizar la comparación de los resultados de las fórmulas empíricas, se calcularon los valores de los estadísticos R^2 y RMSE para las catorce estaciones de aforo estudiadas. Los mejores resultados para cada cuenca se resaltan en negrita en la Tabla 11, siendo éstos los que consiguen un valor de R^2 más alto y un valor de RMSE más bajos.

De acuerdo con los resultados obtenidos, en la mayoría de las estaciones Fuller o la regionalización de la ecuación de Fuller (CEDEX) tienen el mayor coeficiente de determinación y el menor error cuadrático medio. También se puede concluir que la regionalización de la ecuación de Fuller mejora la estimación del Q_{ins} , especialmente en cuencas con un alto índice de torrencialidad, como se observa en los resultados obtenidos en las estaciones de aforo AND, COT, TRE, GAR y CUE. Además, la fórmula de Fill & Steiner obtuvo resultados más precisos en las estaciones PER y PIT, cuencas caracterizadas por un bajo índice de torrencialidad. La fórmula de Sangal exhibe un comportamiento muy regular en general, con resultados más precisos en comparación con Fill & Steiner, pero peores resultados en comparación con la ecuación de Fuller o su regionalización CEDEX. Con respecto a las zonas climáticas, no se observa un patrón claro que indique una preferencia de un método sobre otro.

Tabla 11. Evaluación de los resultados obtenidos con las fórmulas empíricas basada en el valor de R^2 y RMSE.

Cuenca	R^2				RMSE (m ³ /s)			
	Fuller	CEDEX	Sangal	Fill Steiner	Fuller	CEDEX	Sangal	Fill Steiner
TRE	0.85	0.85	0.82	0.80	93.68	76.09	82.16	99.27
BEG	0.89	0.89	0.87	0.88	56.35	59.53	78.09	58.63
COT	0.70	0.70	0.68	0.68	159.65	126.11	137.51	167.11
AND	0.54	0.54	0.61	0.62	184.61	174.11	158.67	177.70
PRI	0.90	0.90	0.89	0.89	9.94	11.04	10.39	11.67
BOL	0.92	0.92	0.94	0.94	6.92	16.28	8.17	9.26
GAR	0.71	0.71	0.69	0.70	12.10	11.20	14.11	15.70
CUE	0.65	0.65	0.66	0.65	30.93	28.23	33.50	35.97
JUB	0.30	0.30	0.29	0.28	14.15	13.97	14.14	14.50
TRA	0.81	0.81	0.84	0.83	3.34	6.38	3.96	4.77
BEL	0.44	0.44	0.43	0.41	7.63	6.79	7.53	7.80
PER	0.92	0.92	0.90	0.91	17.44	20.13	19.49	16.80
RIA	0.72	0.72	0.72	0.71	4.41	3.39	3.27	3.33
PIT	0.87	0.87	0.82	0.85	4.48	16.57	2.80	2.27

A continuación, se realizó la estimación de los Q_{ins} utilizando los modelos de machine learning de RNA y ANFIS. En ambos modelos, el único dato de entrada (input) es el MQ_{md} y la configuración de red óptima se determinó utilizando un proceso iterativo de prueba y error, evaluando el rendimiento para diferentes estructuras de red. En cuanto a la RNA, se consideraron una o dos capas ocultas con un número de neuronas entre dos y veinte, el número máximo de iteraciones de entrenamiento (épocas) fue 1000 y el algoritmo de *backpropagation* de LM fue utilizado para ajustar los pesos adecuados y minimizar el error. La estructura de RNA utilizada en este trabajo se muestra en la Figura 18, donde los datos de entrada son el MQ_{md} y los datos de salida son los Q_{ins} . Se utilizó una función de transferencia tangente sigmoideal en las capas ocultas y una función de transferencia lineal en la capa de salida.




Figura 18. Arquitectura de la RNA de tipo MLP utilizada en la estimación de los Q_{ins} (IPF, por sus siglas en inglés) a partir del Q_{md} (MMDF, por sus siglas en inglés).

Para construir las RNAs y para su entrenamiento, los datos se ingresaron en el software de MATLAB de forma que el 80% de los datos eran para entrenamiento y el 20% de los datos para prueba. La estructura de RNAs con dos capas ocultas y dos neuronas ocultas en cada capa fue la estructura óptima para la mayoría de las cuencas, mientras que la segunda estructura más utilizada tenía una capa oculta con dos neuronas ocultas. En cuanto al modelo ANFIS, en la primera capa, donde cada nodo es un nodo adaptativo y que actúa como una función de pertenencia (MF), se probó con diferentes MFs; y los modelos con la MF sigmooidal y de campana generalizada obtuvieron los resultados más precisos en la fase de validación del modelo.

Los resultados obtenidos por las RNAs, ANFIS y la mejor fórmula empírica en cada cuenca se muestran en la Tabla 12, con los mejores resultados para cada cuenca resaltados en negrita. Los resultados obtenidos se compararon utilizando R^2 y RMSE como criterios de evaluación.

Tabla 12. Estadísticos del ajuste obtenido con los modelos de RNAs, ANFIS y la mejor fórmula empírica en la estimación de Q_{ins} .

Código de la Cuenca	Data set	RNA		ANFIS		Mejor fórmula empírica		Fórmula
		R ²	RMSE	R ²	RMSE	R ²	RMSE	
TRE	Entrenamiento	0.92	55.30	0.92	54.81	0.86	78.94	CEDEX
	Test	0.66	52.95	0.67	47.80	0.53	62.55	
BEG	Entrenamiento	0.70	90.69	0.92	47.86	0.88	58.38	Fuller
	Test	0.83	72.03	0.87	59.31	0.95	47.07	
COT	Entrenamiento	0.77	117.19	0.79	107.49	0.69	134.55	CEDEX
	Test	0.82	70.04	0.82	68.80	0.91	84.26	
AND	Entrenamiento	0.46	170.75	0.50	163.13	0.53	159.13	Sangal
	Test	0.75	172.29	0.79	188.60	0.83	156.92	
PRI	Entrenamiento	0.89	9.75	0.91	9.00	0.88	10.26	Fuller
	Test	0.98	5.62	0.98	4.80	0.96	8.52	
BOL	Entrenamiento	0.97	4.60	0.99	1.70	0.95	7.48	Fuller
	Test	0.78	3.27	0.77	4.50	0.72	4.09	
GAR	Entrenamiento	0.82	8.62	0.94	5.06	0.71	11.29	CEDEX
	Test	0.75	10.36	0.85	8.46	0.72	10.72	
CUE	Entrenamiento	0.85	12.26	0.90	10.24	0.75	17.34	CEDEX
	Test	0.79	44.92	0.77	41.38	0.85	52.07	
JUB	Entrenamiento	0.39	10.31	0.41	10.12	0.32	11.10	CEDEX
	Test	0.50	20.27	0.59	19.51	0.48	21.38	
TRA	Entrenamiento	0.83	2.88	0.84	2.76	0.82	3.38	Fuller
	Test	0.83	2.66	0.80	2.70	0.83	3.15	
BEL	Entrenamiento	0.49	6.44	0.60	5.61	0.47	7.12	CEDEX
	Test	0.84	6.23	0.77	7.21	0.80	7.99	
PER	Entrenamiento	0.91	16.87	0.93	14.33	0.90	17.64	Fill-Steiner
	Test	0.96	7.39	0.98	5.44	0.92	9.28	
RIA	Entrenamiento	0.73	3.27	0.75	3.11	0.71	3.50	Sangal
	Test	0.88	1.64	0.86	2.33	0.88	2.11	
PIT	Entrenamiento	0.80	2.29	0.86	2.13	0.79	2.25	Fill-Steiner
	Test	0.92	2.20	0.97	0.82	0.97	2.07	

Con los resultados de la Tabla 12 se puede concluir que el R² más alto y el RMSE más bajo se obtuvieron utilizando el método ANFIS en la mayoría de las estaciones. Estos resultados apoyan los resultados de Dastorani et al. (2013) y Fathzadeh et al. (2017). Con respecto al método de RNAs, la precisión de los

resultados es, en general, más alta que los resultados obtenidos utilizando las fórmulas empíricas, pero menor en comparación con los resultados obtenidos con ANFIS. Como se muestra en los datos de la cuenca RIA, las estimaciones obtenidas usando la RNA resultaron más precisas cuando las series de datos de caudales utilizadas como datos de entrada eran más largas, es decir, se disponía de más datos para el entrenamiento del modelo. En general, los resultados obtenidos mediante técnicas de aprendizaje automático (RNA y ANFIS) son claramente más precisos que los obtenidos con las fórmulas empíricas. Solo en las cuencas AND y BEG las fórmulas empíricas mejoran los resultados obtenidos con estas técnicas. Estos resultados pueden observarse gráficamente en las gráficas de la Figura 19, donde se compara la pendiente de la línea de regresión lineal con la línea 1:1 y el coeficiente de correlación entre los valores observados y medidos de los Q_{ins} obtenidos con las RNA y ANFIS. En las gráficas, ANFIS parece ser ligeramente mejor en la mayoría de las estaciones de aforo estudiadas puesto que los resultados se concentran más próximos a la línea 1:1 y el coeficiente de correlación es más cercano a 1. Sin embargo, las diferencias entre ambas técnicas aumentan cuando se analizan los resultados de los errores, como se mostraba en la Tabla 12.

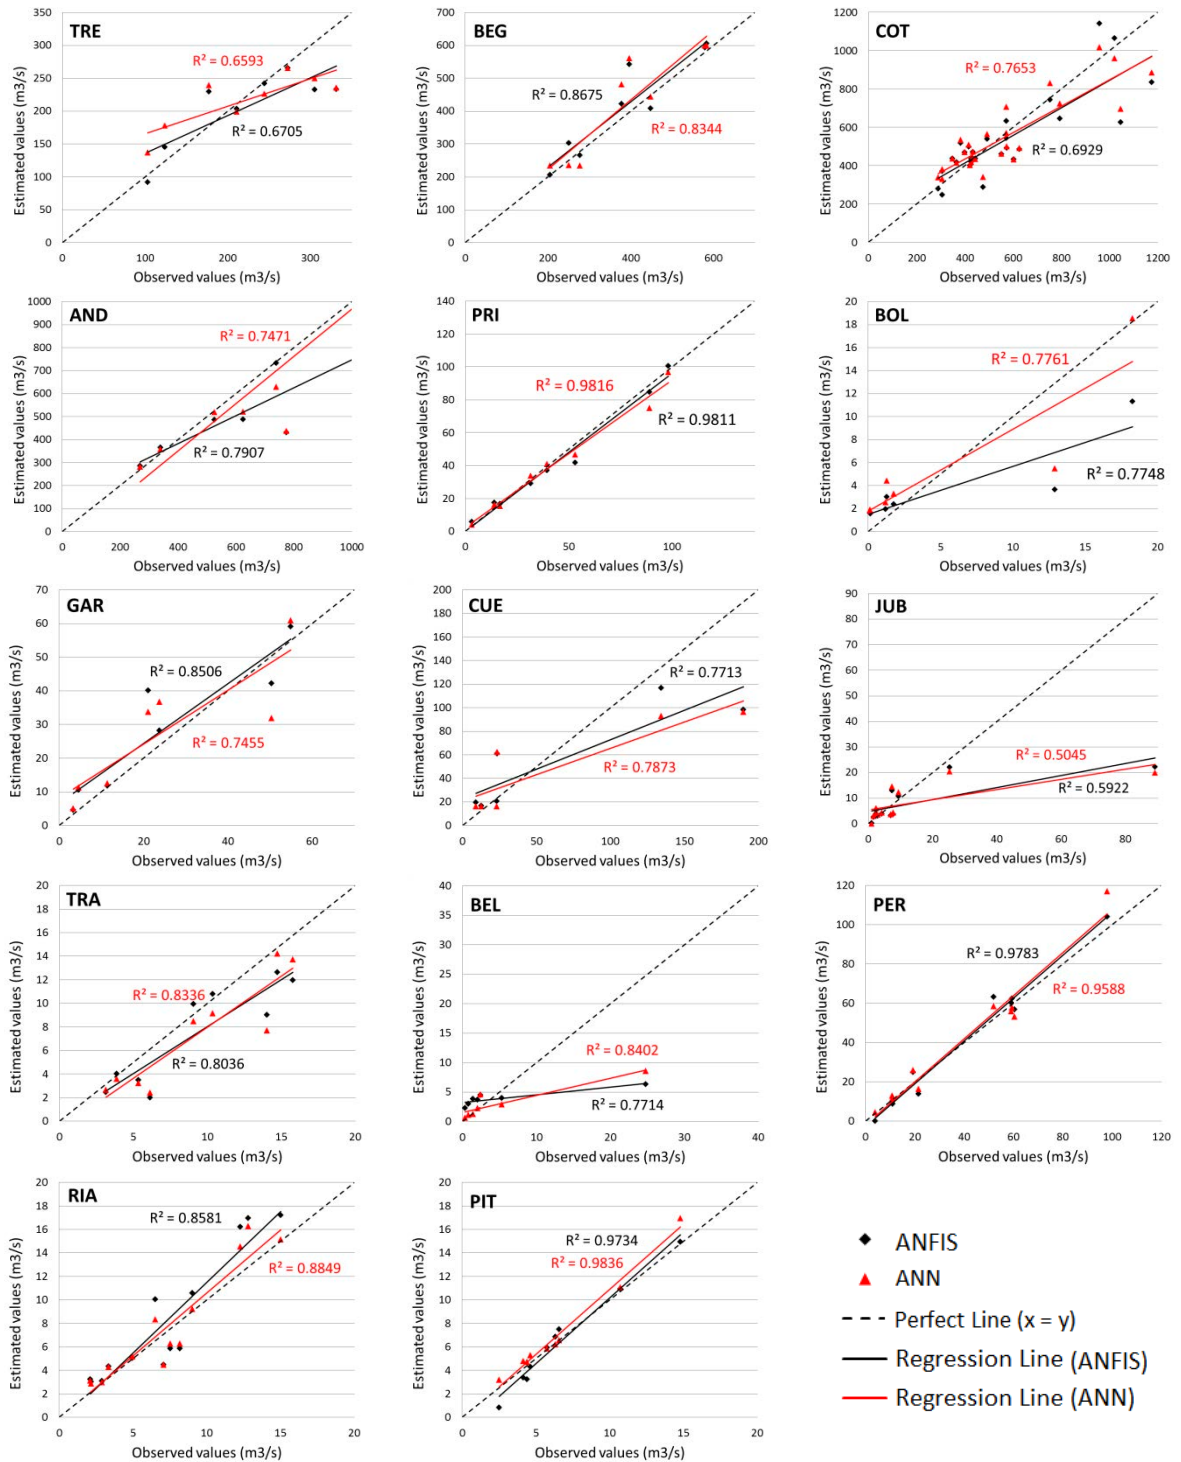


Figura 19. Diagramas de dispersión del Q_{ins} observado y el estimado obtenido con el modelo de RNA versus ANFIS para la fase de test. Las letras en la parte superior izquierda de cada subfigura muestran los códigos de la cuenca (ver Tabla 2).

4.5.3 Combinación de las técnicas de machine learning con SWAT para la predicción de caudales máximos instantáneos

En la cuenca del río Ladra se evaluó la idoneidad del modelo SWAT para simular caudales y se analizó el rendimiento de diferentes técnicas de machine learning, como RNAs, ANFIS, SVM y ELM, para predecir el Q_{ins} a partir del MQ_{md} obtenido con el modelo SWAT. Para lograr estos objetivos, este estudio se dividió en una primera parte de calibrado y validación del modelo SWAT para la obtención de una serie de caudales medios diarios más larga de la disponible. Después, una segunda parte de análisis del rendimiento de los diferentes sistemas inteligentes para estimar el Q_{ins} .

4.5.3.1 Estimación de los máximos caudales medios diarios con el modelo SWAT

Para esta parte de la investigación, el modelo SWAT de la cuenca del río Ladra se realizó utilizando los datos climáticos proporcionados por la agencia meteorológica regional (Meteogalicia). El primer paso en la calibración del modelo SWAT fue identificar de entre 19 parámetros aquellos que eran más sensibles relacionados con el caudal. En este análisis de sensibilidad, todos los parámetros van cambiando, y se necesita una gran cantidad de ejecuciones para ver el impacto de cada parámetro en la función objetivo (Abbaspour, Vaghefi, & Srinivasan, 2018). Debido al hecho de que solo los caudales altos son de interés en esta parte del trabajo, como función objetivo se estableció el coeficiente de eficiencia de Nash-Sutcliffe modificado (MNSE) para así aumentar la sensibilidad a caudales altos de acuerdo con Krause, Boyle, & Bäse (2005).

Se obtuvo un ranking de las sensibilidades de los parámetros después de 500 ejecuciones, eliminando así los parámetros identificados como no sensibles. Los parámetros más sensibles se enumeran en la Tabla 13. Posteriormente, para los parámetros más sensibles se introdujo un rango de valores realista obtenido a partir de la experiencia y del conocimiento hidrológico de la cuenca, para así realizar una auto-calibración utilizando el algoritmo SUFI-2 en el programa SWAT-CUP.

Tabla 13. Parámetros calibrados en el modelo SWAT para la cuenca del río Ladra con el objetivo de obtener los MQ_{md}.

Parámetros	Descripción	Rango	Valor inicial	Valor ajustado
CN2	SCS número de curva	20-90	61-83	+15.71%
GWQMN	Profundidad umbral de agua en el acuífero superficial para que se produzca flujo de retorno (mm)	0-5000	1000	452.88
ALPHA_BF	Coefficiente de agotamiento del flujo base (días ⁻¹)	0-1	0.048	0.0681
CNCOEF	Coefficiente para el cálculo del número de curva dependiente de la evapotranspiración de la planta	0.5-2	1	0.7645
GW_DELAY	Tiempo de retardo del agua subterránea (días)	0-500	31	1.1704
RCHRG_DP	Factor de percolación al acuífero profundo	0-1	0.05	0.0313
REVAPMN	Umbral de profundidad del agua en el acuífero superficial para "revaporación" a la capa de suelo o percolación al acuífero profundo (mm)	0-500	500	48.85
SOL_AWC	Capacidad de agua disponible de la capa del suelo (mm H ₂ O/mm suelo)	0-1	0.12-0.16	-18.48%
ESCO	Factor de compensación de la evaporación del suelo	0-1	0.95	0.7027
EPCO	Factor de compensación de la captación de las plantas	0-1	1	0.3778
SLSUBBSN	Longitud promedio de la pendiente (m)	10-150	24-92	+0.04%
OV_N	Número de Manning para el flujo terrestre	0.01-1	0.1	0.7529
CH_K1	Conductividad hidráulica efectiva en canales tributarios (mm/h)	0-300	0	44.18
CH_K2	Conductividad hidráulica efectiva en canal principal (mm/h)	0-150	0	140.93
CH_N1	Número de Manning en los canales tributarios	0.01-0.3	0.014	0.2901

Analizando los valores de los parámetros calibrados de la Tabla 13, se observa como el parámetro del número de curva (CN2) aumentó en un 15% en

comparación con el valor predeterminado, disminuyendo así la infiltración y aumentando la escorrentía. La capacidad de agua disponible en la capa de suelo (SOL_AWC) se redujo en un 18% aumentando así el movimiento del agua dentro de los perfiles del suelo (Qiu, Zheng, & Yin, 2012). El coeficiente de compensación de evaporación del suelo (ESCO) se redujo después de la calibración de 0.95 a 0.70, aumentando la capacidad del modelo para extraer la demanda de evaporación de las capas más bajas del suelo. De acuerdo con Abbaspour et al. (2015), se esperaban estos cambios en CN2, SOL_AWC y ESCO para así aumentar los caudales máximos simulados. El factor de compensación de absorción de la planta (EPCO) también se redujo después de la calibración, aumentando la evapotranspiración generada por el modelo. El valor de la constante de recesión del flujo base (ALPHA_BF) obtenida para la cuenca del río Ladra (0.07) indica una respuesta rápida de la escorrentía a los afloramientos de formaciones geológicas de lluvia de baja permeabilidad en la cuenca. Los valores calibrados de otros parámetros del agua subterránea, como la profundidad umbral del agua en el acuífero poco profundo para que ocurra el flujo de retorno (GWQMN), el retardo del agua subterránea (GW_DELAY) y la profundidad umbral del agua en el acuífero superficial para la filtración al acuífero profundo (REVAPMN), fueron muy similares a los utilizados por Malagó et al. (2015) para cuencas hidrográficas del noroeste de España. De hecho, GW_DELAY se redujo considerablemente durante la calibración, lo que es consistente con la respuesta rápida a los episodios húmedos observados en los hidrogramas de la cuenca del río Ladra. La fracción de percolación al acuífero profundo (RCHRG_DP) es muy cercana a cero debido a que las formaciones geológicas de la zona no favorecen un almacenamiento de agua subterránea duradero y relevante. El alto valor obtenido del número de Manning para el flujo terrestre (OV_N), está relacionado con la vegetación abundante, como es típico en el noroeste de España (Raposo et al., 2013).

Para medir el rendimiento del modelo SWAT, se utilizaron dos medidas estadísticas que pudieran comparar los caudales simulados con los caudales observados en la estación de aforo, se empleó el índice de NSE modificado y el índice de concordancia (*d*) modificado. En este estudio, siguiendo las sugerencias de Krause et al. (2005), las diferencias entre valores simulados y observados están elevados al cubo en vez de al cuadrado (ver Ecuación 2 y Ecuación 3 de la

Publicación 3). De esta forma, aumentamos la sensibilidad de los criterios de eficiencia a los caudales altos, ya que estos son los caudales de interés en esta parte de la investigación. Teniendo en cuenta que el rango del MNSE se encuentra entre 1 (ajuste perfecto) y $-\infty$, mientras que el rango del índice d se encuentra entre 1 (ajuste perfecto) y 0 (sin correlación), los resultados que se muestran en la Tabla 14 muestran que el rendimiento del modelo calibrado fue satisfactorio en la reproducción de los caudales máximos.

Tabla 14. Valores iniciales de MNSE y d , y valores para la fase de calibración y validación de los caudales diarios.

Valores iniciales		Calibración		Validación	
MNSE	d	MNSE	d	MNSE	d
-0.25	0.67	0.68	0.93	0.64	0.95

Utilizando los datos de caudales diarios simulados para el período 1973-2014, se trazó la curva de duración del caudal y se comparó con la CDC construida a partir de los caudales diarios observados (Figura 20a).

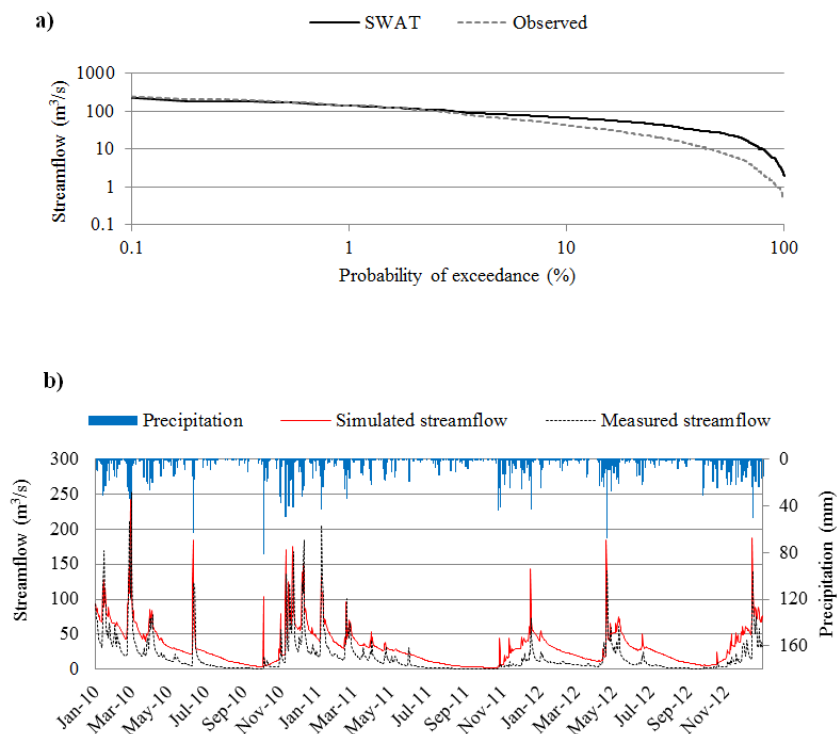


Figura 20. Comparación de los caudales diarios observados y simulados con SWAT en el periodo de validación del río Ladra; (a) curvas de duración de caudales; (b) hidrograma diario.

Las CDCs se emplearon como una medida gráfica para ilustrar el rendimiento del modelo SWAT en la simulación de los valores más altos del caudal. Como era de esperar, debido a la función objetivo utilizada en la calibración del modelo, hay una sobreestimación de los caudales bajos. Sin embargo, los caudales del percentil 5 (Q5) se simularon con una precisión razonable. Y debido a que el objetivo de esta parte de la investigación es obtener un buen funcionamiento de SWAT al simular los valores más altos del caudal se pueden aceptar estos resultados.

4.5.3.2 Estimación de caudales máximos instantáneos utilizando técnicas de machine learning

El software MATLAB se volvió a emplear para desarrollar, entrenar y probar las técnicas de aprendizaje automático. Para estimar el Q_{ins} , se realizó una validación cruzada 5-fold para evaluar el rendimiento de las técnicas de aprendizaje automático. Para ello el conjunto de datos se dividió en 5 subconjuntos, y el mismo proceso se repitió 5 veces. Cada vez, uno de los 5 subconjuntos se usó como conjunto de test y los otros 4 subconjuntos se utilizaron para formar el conjunto de entrenamiento. A continuación, se calcularon los estadísticos R^2 y RMSE, sus promedios y desviaciones estándar de los obtenidos en las 5 pruebas. El rendimiento de los modelos RNA, ANFIS, SVM (Kernel lineal) y ELM (kernel Gaussiano) se compararon después de las fases de entrenamiento y de la fase de test. La Tabla 15 muestra los resultados del análisis estadístico en términos de R^2 y RMSE.

Tabla 15. Estadísticos obtenidos en la fase de entrenamiento y de test (media \pm desviación estándar de la validación cruzada) en la estimación del Q_{ins} .

Estadístico	Fase	RNA	ANFIS	SVM	ELM
R^2	Entrenamiento	0.80 \pm 0.16	0.81 \pm 0.18	0.89 \pm 0.03	0.91 \pm 0.02
	Test	0.74 \pm 0.37	0.69 \pm 0.35	0.88 \pm 0.15	0.86 \pm 0.12
RMSE	Entrenamiento	67.27 \pm 25.71	65.29 \pm 30.81	56.29 \pm 5.49	59.96 \pm 16.54
	Test	86.00 \pm 82.32	106.30 \pm 76.60	55.51 \pm 23.74	48.59 \pm 4.80

De acuerdo con estos resultados, RNA, ANFIS, SVM (kernel lineal) y ELM (kernel Gaussiano) se caracterizaron por valores medios de R^2 de 0.80, 0.81, 0.89 y 0.91 para los datos de entrenamiento y 0.74, 0.69, 0.88 y 0.86 para los datos de test.

Con base al R^2 obtenido, los cuatro modelos produjeron resultados aceptables para ambas fases; SVM y ELM mostraron el mejor rendimiento, y ANFIS mostró el peor. En términos del RMSE, los resultados fueron similares respecto R^2 y ELM, con kernel Gaussiano mostró el mejor rendimiento. Estos resultados están de acuerdo con los obtenidos por Bezdah, Asghari, Eazi, & Palhang (2009); quienes encontraron que la precisión de predicción de los caudales de valores altos usando SVM era mejor que las obtenidas con modelos de RNAs.

4.5.3.3 Aplicación conjunta del modelo SWAT y de la técnica de ELM para la predicción del caudal máximo instantáneo

Una vez que demostrado que el modelo SWAT podía reproducir los caudales máximos medios diarios y que la técnica de ELM era la mejor opción para estimar los Q_{ins} a partir del MQ_{md} , la aplicación de acoplamiento de ambas técnicas se utilizó para la predicción del Q_{ins} (Figura 21). Como se puede ver en la Figura 21, el modelo SWAT calibrado se aplicó para el período 1973-2014, obteniendo así 41 valores de MQ_{md} ; en este periodo los Q_{ins} reales (observados) estaban disponibles. A continuación, se utilizó el modelo de ELM para estimar los Q_{ins} .

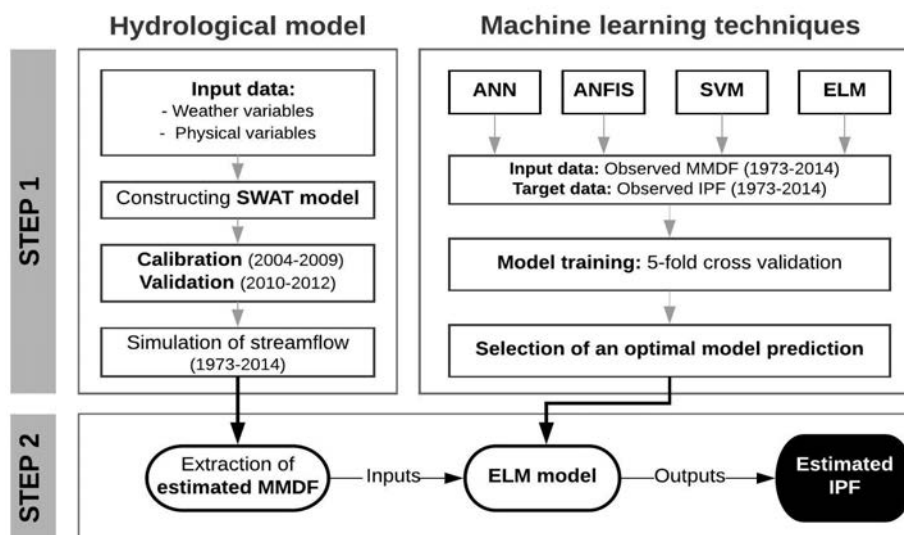


Figura 21. . Diagrama de la aplicación de acoplamiento de SWAT y la técnica de machine learning (ELM) para predecir Q_{ins} (IPF, por sus siglas en inglés).

La Figura 22 muestra los valores de Q_{ins} estimados frente a los valores observados para el período de estudio.




Figura 22. Comparación entre el valor estimado y observado de Q_{ins} (IPF, por sus siglas en inglés) para el periodo (1973-2014) en la cuenca del río Ladra

Los Q_{ins} estimados se subestimaron en comparación con los datos observados, pero el valor de R^2 obtenido tras comparar los datos observados y estimados fue de 0.54, lo que representa un rendimiento adecuado. Estos resultados muestran la solidez de la aplicación combinada del modelo SWAT y la técnica ELM. Estos resultados son consistentes con estudios previos (Sudheer, Nayak, & Ramasastri, 2003) que también encontraron una subestimación en la predicción del Q_{ins} usando técnicas de aprendizaje automático.

Debido a la gran influencia de la longitud de los datos registrados y a la calidad de los datos de Q_{ins} en el diseño de inundaciones (Ding, Wallner, Müller, & Haberlandt, 2016), la aplicación acoplada de estas técnicas puede ser una solución para extender la serie de datos de Q_{ins} en cuencas con registros de datos deficientes.

4.5.4 Uso combinado de modelos geoestadísticos e hidrológicos para evaluar errores sistemáticos en la medición de la precipitación en cuencas alpinas

Los datos de caudales diarios de la cuenca se obtuvieron de la web del CEDEX y estaban disponibles a partir de 1988. Los datos de precipitación y temperatura fueron provistos por cuatro agencias españolas: la Agencia estatal de meteorología (AEMET), el Instituto de Investigación y Formación Agraria y Pesquera (IFAPA), el Parque Nacional de Sierra Nevada (PNS) y la Red de Información Ambiental de Andalucía (REDIAM). En total, se utilizaron 119 pluviómetros y 72 medidores de temperatura. Se han utilizado los datos de precipitación obtenidos en la investigación de Collados-Lara, Pardo-Iguzquiza, & Pulido-Velazquez (2018). Collados-Lara et al., (2018), en su trabajo, estimaron la precipitación para la cuenca del Alto Genil, cuenca donde está ubicada la cuenca de Canales, usando *Kriging* con deriva externa (KED) lineal y cuadrática, y *Regression-kriging* (RK) con una resolución de 1x1 km. Los datos de temperatura utilizados en este trabajo fueron también estimados para la cuenca Alto Genil usando KED con deriva externa. Con estos datos de precipitación y de temperatura se calibraron los modelos STM.

En la Tabla 16 se incluye un resumen de los resultados mensuales obtenidos con el modelo STM calibrado automáticamente en términos del factor de corrección para la precipitación sólida (Cs) y líquida (Cr), y su bondad de ajuste a los datos diarios de caudal. La tabla incluye los resultados de los diferentes experimentos con los diferentes campos climáticos probados, con datos de precipitación KED-lineal y RK, y temperatura obtenida mediante KED-lineal. Los valores numéricos de NSE, R^2 y RMSE muestran que la eficiencia de los modelos aumenta al corregir la precipitación.

Tabla 16. Bondad de ajuste a escala mensual del modelo STM para los datos de calibración y validación y valores de Cr y Cs para cada experimento.

Approaches of climatic fields	Cs	Cr	Calibration			Validation		
			NSE	R ²	RMSE	NSE	R ²	RMSE
RK	1.78	1.4	0.68	0.70	3.39	0.63	0.67	2.66
RK (Cs=Cr=1; non-recalibrated model)	1	1	0.06	0.70	5.79	- 0.001	0.55	4.37
RK (Cs=Cr=1; recalibrated model)	1	1	0.46	0.64	4.35	0.42	0.52	3.33
Linear KED	1.8	1.07	0.34	0.57	4.80	0.43	0.71	3.29
Linear KED (Cs=Cr=1; non-recalibrated model)	1	1	- 0.08	0.48	6.15	0.49	0.62	3.11
Linear KED (Cs=Cr=1; recalibrated model)	1	1	0.04	0.45	5.82	0.47	0.60	3.18

En todos los casos simulados, la precipitación corregida muestra un incremento medio importante con respecto a los valores históricos medios. A la izquierda de la Figura 23, se observan las distribuciones temporales de la precipitación original y su precipitación corregida de cada experimento. El período con la mayor corrección de la precipitación va de octubre a mayo, donde se encuentran los meses con posibles nevadas. Durante los meses de verano, de junio a septiembre, se obtuvo una menor corrección de la precipitación. En los datos de precipitación KED-lineal, la corrección de la precipitación se vuelve casi cero o completamente nula en los meses de verano, donde solo hay precipitación líquida y el *under-catch* parece ser casi despreciable. A la derecha de la Figura 23, los gráficos circulares muestran la distribución de la precipitación con su proporción de precipitación sólida y líquida. El porcentaje de precipitación sólida es mayor en los modelos corregidos como era de esperar, mostrando que la subestimación de la precipitación sólida es mayor que para la líquida.

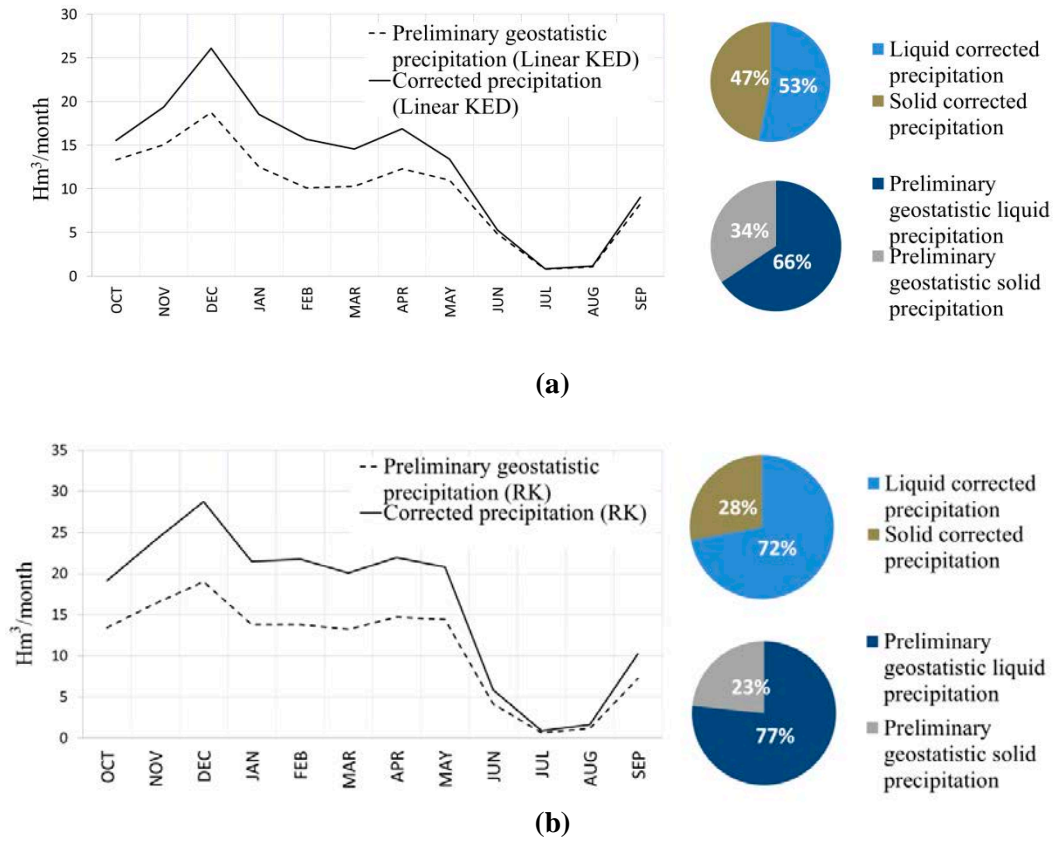




Figura 23. Precipitación mensual media corregida frente a la estimada y su distribución anual entre fase líquida y sólida; (a) experimento Linear KED; (b) experimento RK

El caudal mensual simulado frente al observado en la salida de la cuenca se muestra en la Figura 24a y 24b. Los resultados obtenidos incluyendo un factor de corrección global para modificar la intensidad de la precipitación son significativamente mejores que los obtenidos sin ninguna corrección como puede verse en la Figura 24. En ambas figuras hay tres series simuladas representadas para cada experimento, una corresponde a la simulación con los valores óptimos de C_r y C_s , y las demás corresponden a la simulación con $C_r = C_s = 1$, es decir, sin corrección de precipitación, una calibrando de nuevo el modelo y otra sin calibrar.



(a)



(b)

- Observed streamflow
- - Simulated streamflow with geostatistic data
- Simulated streamflow with geostatistic data ($C_s=C_r=1$; recalibrated model)
- · Simulated streamflow with geostatistic data ($C_s=C_r=1$; non-recalibrated model)

Figura 24. Caudal mensual medio (año medio); (a) utilizando precipitación del experimento RK; (b) utilizando precipitación del experimento Linear KED

De acuerdo con los resultados, se obtiene que la mejor combinación de datos geoestadísticos con el modelo hidrológico STM es el enfoque RK y con la precipitación sólida y líquida corregida con los coeficientes calibrados C_s y C_r . La bondad de ajuste al caudal diario y mensual para los períodos de calibración y validación es mejor para los datos RK que para los datos del enfoque KED-lineal según los estadísticos R^2 , NSE y RMSE. Para la fase de validación, los valores de NSE fueron 0.56 para la escala diaria y 0.68 para la escala mensual. Los valores de R^2 fueron 0.58 y 0.70 para la escala diaria y mensual respectivamente. Pudiéndose concluir que si no se corrigen los datos de precipitación, resulta difícil aproximar los caudales simulados a los caudales observados, sobre todo a aquellos que tienen lugar durante el final de la primavera en el período de fusión. Sin embargo, los modelos con la precipitación corregida para ambos enfoques geoestadísticos (RK y KED-lineal) siguen subestimando el pico de los hidrogramas (Figura 24a y 24b), pero son claramente más precisos que los caudales obtenidos sin corregir la precipitación. En la Figura 24a y 24b se puede ver la existencia de una estación lluviosa que va desde el otoño hasta mediado de la primavera y una estación muy seca a finales de la primavera y el verano. Sin embargo, los mayores caudales de agua en el río ocurren al final de la primavera, específicamente en mayo y junio. Esto es debido a la dinámica de la nieve que caracteriza a esta cuenca. Los principales impulsores de la dinámica hidrológica de Sierra Nevada son la presencia de nieve y la persistencia; estos procesos amortiguan la generación de escorrentías y mantienen la humedad del suelo, prolongando el flujo de agua en los ríos mucho después de la estación húmeda y, en última instancia, determinando la distribución del hábitat (Herrero y Polo, 2016). El factor de corrección óptimo obtenido para la mejor simulación del modelo STM fue 1.78 para la precipitación sólida y 1.40 para la precipitación líquida. Es decir, cada dato de precipitación debe incrementarse un 78% en el caso de ser precipitación sólida y un 40% en el caso de ser líquida. Las Figuras 24a y 24b muestran una simulación pobre frente al caudal observado cuando la precipitación no es corregida, mostrando una gran subestimación del caudal en la primavera, estación del deshielo, debido a la menor cantidad de nieve considerada en invierno. Otros estudios obtuvieron resultados similares. Irannezhad et al., (2015) tras una revisión de los trabajos existentes en la literatura estableció que el rango de valores para C_r era de 1.01 a 1.40, y el rango para C_s de 1.05 a 1.8.

La Figura 25 muestra como el modelo STM con los datos de precipitación del enfoque RK simuló mejor los caudales que con la precipitación KED-lineal, obteniendo mejores resultados reproduciendo el flujo base.

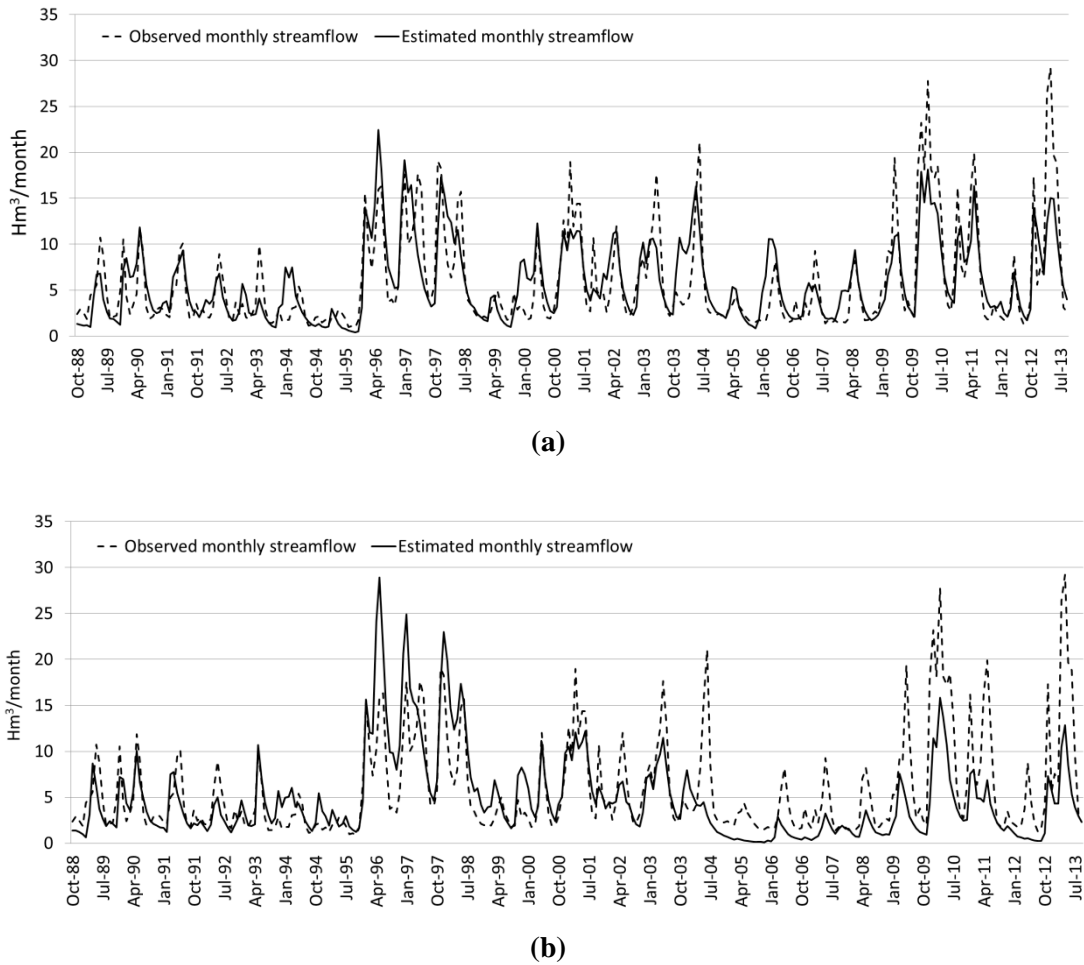


Figura 25. Caudal mensual simulado frente al observado; (a) con datos de precipitación RK; (b) con datos de precipitación KED-Lineal.

Por otro lado, los valores de precipitación corregidos permiten evaluar el patrón de precipitación corregido con la altitud (gradiente con la altitud) en esta cuenca alpina (Figura 26).




Figura 26. Precipitación diaria media corregida según la elevación de la cuenca frente a la precipitación sin corregir.

Con respecto a la precipitación corregida, para KED-lineal se obtuvo un aumento de la precipitación especialmente en las elevaciones más altas debido a que el coeficiente de corrección para la precipitación en forma de nieve es más alto que el coeficiente de corrección de la precipitación líquida (1.80 vs 1.07 respectivamente). Para el enfoque RK, la diferencia entre estos coeficientes es menos importante, 1.78 para la precipitación sólida y 1.40 para la líquida. Esto reduce el gradiente negativo de precipitación inicialmente predicho por el RK para altitudes superior a 1000 m, debido a la inversión del fenómeno de gradiente descrito en Collados-Lara et al. (2018). En el trabajo de Collados-Lara et al. (2018) se realizó una corrección preliminar de los datos experimentales en la cuenca del Alto Genil mediante la aplicación de las funciones de corrección experimentales propuestas por Buisan et al. (2017) para algunas montañas españolas. Para la cuenca de Canales se obtuvo un coeficiente de corrección promedio de 1.17 y 1.09 para KED-lineal y RK respectivamente si la elevación es inferior a 2000 metros y 1.29 y 1.28 para KED-lineal y RK respectivamente si la elevación es superior a 2000 metros. Estos valores son menores que los obtenidos en este estudio. Sin embargo, las funciones de corrección utilizadas en Collados-Lara et al. (2018) se obtuvieron para otras cadenas montañosas, y no hay ninguna específicamente disponible para nuestro caso de estudio.

**V – CONCLUSIONES Y
FUTURAS LÍNEAS DE
INVESTIGACIÓN**

V –CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

Los modelos físicamente basados tienen la ventaja de considerar los procesos físicos de control, pero al mismo tiempo sus requisitos de datos también son altos. A menudo, incluso en cuencas hidrográficas intensamente monitorizadas, todos los datos requeridos no están disponibles. Por lo tanto, existe la necesidad de buscar métodos alternativos para la predicción de variables hidrológicas utilizando información fácilmente disponible (p. e., precipitación y temperatura).

En la **Publicación 1** de la presente tesis se propuso el uso de SWAT, un modelo físicamente basado, y de las RNAs, una técnica de aprendizaje automático, para simular los valores de caudales diarios y comparar los resultados de ambos modelos para analizar sus rendimientos. Se aplicaron ambos modelos en dos cuencas con climas muy diferentes para verificar la validez de estos modelos en cuencas con diferentes condiciones climáticas. Para determinar el tipo y número de inputs para los modelos de RNAs, se consideraron cuatro escenarios en cada cuenca estudiada, y se mostró que la inclusión de la precipitación diaria, la precipitación de días previos y la precipitación total de los días previos era importante para estimar el caudal diario. Después de calibrar los modelos SWAT para el caudal diario observado empleando el algoritmo SUFI-2, los resultados indicaron que SWAT tuvo un mejor rendimiento en la estimación de valores muy bajos de caudal, mientras que las RNAs estimaron los valores muy altos con mayor precisión en todos los casos estudiados. Además, los resultados sugieren que los modelos SWAT y las RNAs eran mejores cuando el clima era más húmedo. Cuando la cuenca tiene un clima más árido y, por lo tanto, es más complicado de modelar, la RNA obtuvo un mejor rendimiento en más fases del hidrograma. Una de las ventajas del modelo de RNA es que no requiere ninguna característica física de la cuenca y, por lo tanto, su implementación es más fácil. Sin embargo, esto es también una de sus principales críticas. Siendo todavía necesario desarrollar modelos de estimación de caudales con ideas conceptuales para reflejar las características de los caudales. Una RNA es una caja

negra, y para obtener conocimiento sobre el balance hídrico y sus componentes, el modelo SWAT es más útil. A pesar de las ventajas y desventajas de cada modelo, los resultados sugieren que para simular los valores de las series temporales de caudales, la elección entre el SWAT o RNA tiene un impacto en la precisión del caudal estimado. Esta idea de modelar series temporales de caudales también puede extenderse a otras técnicas de aprendizaje automático, las cuales podrían ser exploradas en futuros trabajos. Además, el modelo de RNA estudiado solo considera las entradas de precipitación y temperatura. Las influencias de otros datos de entradas relacionados con el caudal también se pueden explorar adicionalmente en futuros trabajos para mejorar el estudio actual.

En cuanto a la segunda fase de esta tesis, la estimación de caudales máximos instantáneos es esencial para la gestión de inundaciones y para el diseño de estructuras hidráulicas, especialmente en países como España, donde las inundaciones repentinas son una ocurrencia común y pueden causar daños significativos. En esta investigación, en la **Publicación 2**, las fórmulas empíricas encontradas en la literatura y dos algoritmos de machine learning se aplicaron para estimar el Q_{ins} a partir del MQ_{md} . Los resultados mostraron que el uso de modelos de aprendizaje automático de tipo difuso, como ANFIS, era más preciso en general que las RNAs. Estas conclusiones sugieren que ANFIS puede ayudar a aumentar la precisión de la estimación de los Q_{ins} , siempre y cuando haya disponible una serie larga de datos de MQ_{md} , aunque la disponibilidad de las series de Q_{ins} sea más corta. Por tanto, los métodos de aprendizaje automático son superiores a las fórmulas empíricas con los datos utilizados y en las cuencas caso de estudio, y se necesitarían futuros estudios más extensos con más datos para obtener mejores estimadores. Por otro lado, la dinámica no lineal de la relación entre el Q_{ins} y MQ_{md} justifica los buenos resultados obtenidos por el método ANFIS y RNAs. El principal inconveniente de estos métodos de aprendizaje automático frente al uso directo de las fórmulas empíricas, fue el tiempo que se tardó en implementarlos. Encontrar la estructura óptima de una red neuronal y las MFs apropiadas en ANFIS se determina a través de un proceso de prueba y error, y por lo tanto, requieren largas pruebas y recursos computacionales mucho mayores que las requeridas por las fórmulas empíricas.

En la **Publicación 3**, se exploró la posibilidad de acoplar un modelo SWAT con técnicas de aprendizaje automático para obtener la magnitud del Q_{ins} , que es

fundamental para la evaluación del riesgo de inundación. La comparación entre los caudales diarios medios máximos simulados con los caudales observados correspondientes, indicó que el uso del modelo SWAT era adecuado para estimar los caudales máximos en una escala de tiempo diaria en la cuenca del río Ladra. Para superar la incapacidad del modelo SWAT para obtener caudales máximos instantáneos, se evaluaron diferentes sistemas inteligentes (RNA, ANFIS, SVM y ELM). Como resultado de esta evaluación, todas las técnicas de aprendizaje automático investigadas en este estudio se pueden usar en la predicción de Q_{ins} , aunque la técnica ELM se comportó ligeramente mejor que los otros métodos. Concluyendo que los resultados de este estudio pueden contribuir en las tareas de predicción de los Q_{ins} en áreas donde los datos a escalas de tiempo sub-diarias son escasos o no están disponibles, pudiendo así reducir las incertidumbres asociadas a estas estimaciones.

En la última parte de esta tesis, la cual se corresponde con la **Publicación 4**, se emplea un modelo distribuido de nieve acoplado en el modelo agregado de Témez para simular caudales en una cuenca alpina. En trabajos futuros se podrían realizar otros experimentos con modelos hidrológicos distribuidos. En este enfoque preliminar se ha asumido un valor invariante (en el espacio y el tiempo) del *under-catch* (factor de corrección) de la precipitación sólida y líquida. En el futuro, podrían explorarse otras aproximaciones, por ejemplo, valores de corrección proporcionales a la intensidad del campo de viento. Se ha empleado un método de grado-día para abordar el proceso de fusión dentro del modelo de nieve, y aunque no es un enfoque de balance energético, si considera de manera simplificada la influencia de algunas variables clave relacionadas con el balance de energía. El modelo ha sido calibrado tratando de minimizar las diferencias con respecto a las observaciones del caudal. En trabajos futuros una calibración multicriterio podría ser explorada, también considerando otras variables hidrológicas, como la evolución del área de cobertura de nieve. En este estudio, se han utilizado datos climáticos obtenidos con diferentes enfoques geoestadísticos para modelar los caudales en la cuenca de Canales, en el sur de España. Se ha analizado el patrón de la precipitación en términos de distribución entre fase sólida y líquida y su gradiente espacial con respecto a la elevación. Los datos de precipitación han sido corregidos por dos factores correctores, C_s y C_r , mostrando claramente la existencia del fenómeno de *under-catch* en la precipitación y la

necesidad de corregirla para mejorar los resultados de las simulaciones de caudales. Los resultados muestran que las series históricas de caudal solo se pueden simular adecuadamente cuando suponemos un *under-catch* de la precipitación (1.4 y 1.78 para la precipitación líquida y sólida respectivamente). Esta es la única manera de poder aproximarse al caudal histórico promedio anual y captar el pico del hidrograma debido al proceso de fusión de la nieve.

VI - REFERENCIAS BIBLIOGRÁFICAS

VI – REFERENCIAS BIBLIOGRÁFICAS

Abbaspour, K. C., Johnson, C. A., & Van Genuchten, M. T. (2004). Estimating uncertain flow and transport parameters using a sequential uncertainty fitting procedure. *Vadose Zone Journal*, 3(4), 1340-1352. doi:10.2136/vzj2004.1340

Abbaspour, K. C., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H., & Kløve, B. (2015). A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *Journal of Hydrology*, 524, 733-752. <https://doi.org/10.1016/j.jhydrol.2015.03.027>

Abbaspour, K.C., Vaghefi, S.A. & Srinivasan, R. (2018). A Guideline for Successful Calibration and Uncertainty Analysis for Soil and Water Assessment: A Review of Papers from the 2016 International SWAT Conference. *Water*, 10, 6. <https://doi.org/10.3390/w10010006>

Abbaspour, K. C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., ... & Srinivasan, R. (2007). Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. *Journal of hydrology*, 333(2-4), 413-430. <https://doi.org/10.1016/j.jhydrol.2006.09.014>

Abbott, M. B., Bathurst, J. C., Cunge, J. A., O'Connell, P. E., & Rasmussen, J. (1986). An introduction to the European Hydrological System—Systeme Hydrologique Europeen, "SHE", 1: History and philosophy of a physically-based, distributed modelling system. *Journal of hydrology*, 87(1-2), 45-59. [https://doi.org/10.1016/0022-1694\(86\)90114-9](https://doi.org/10.1016/0022-1694(86)90114-9)

Abraham, A., Köppen, M., & Franke, K. (2003). *Design and application of hybrid intelligent systems*. IOS Press: Amsterdam, Países Bajos, 2003; ISBN 978-1-58603-394-1.

Adam, J. C., & Lettenmaier, D. P. (2003). Adjustment of global gridded precipitation for systematic bias. *Journal of Geophysical Research: Atmospheres*, 108(D9). <https://doi.org/10.1029/2002JD002499>

American Society of Agricultural and Biological Engineers [ASABE]. (2017). *Guidelines for Calibrating, Validating, and Evaluating Hydrologic and Water Quality (H/WQ) Models*; ASABE 621 JUN2017; ASABE: St. Joseph, MI, USA.

Amirhossien, F., Alireza, F., Kazem, J., & Mohammadbagher, S. (2015). A comparison of ANN and HSPF models for runoff simulation in Balkhichai River Watershed, Iran. *American Journal of Climate Change*, 4(03), 203. <http://dx.doi.org/10.4236/ajcc.2015.43016>

Arnold, J. G., Allen, P. M., & Bernhardt, G. (1993). A comprehensive surface-groundwater flow model. *Journal of hydrology*, 142(1-4), 47-69. [https://doi.org/10.1016/0022-1694\(93\)90004-S](https://doi.org/10.1016/0022-1694(93)90004-S)

Arnold, J. G., & Fohrer, N. (2005). SWAT2000: current capabilities and research opportunities in applied watershed modelling. *Hydrological processes*, 19(3), 563-572. <https://doi.org/10.1002/hyp.5611>

Arnold, J.G.; Kiniry, J.R.; Srinivasan, R.; Williams, J.R.; Haney, E.B.; Neitsch, S.L. (2012). *Soil and Water Assessment Tool Input/Output Documentation: Version 2012*; Texas Water Resources Institute Technical Report: College Station, TX, USA, 2012; Volume TR-439, Available online: <http://swat.tamu.edu/media/69296/SWAT-IO-Documentation-2012.pdf> (accessed on 20 June 2017).

Arnold, J. G., Srinivasan, R., Muttiah, R. S., & Williams, J. R. (1998). Large area hydrologic modeling and assessment part I: model development. *JAWRA Journal of the American Water Resources Association*, 34(1), 73-89. <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>

ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000a). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:2\(115\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:2(115))

ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000b). Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), 124-137. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:2\(124\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:2(124))

Babbar, R., & Babbar, S. (2017). Predicting river water quality index using data mining techniques. *Environmental Earth Sciences*, 76(14), 504. <https://doi.org/10.1007/s12665-017-6845-9>

Baker, D. B., Richards, R. P., Loftus, T. T., & Kramer, J. W. (2004). A new flashiness index: characteristics and applications to Midwestern rivers and streams. *JAWRA Journal of the American Water Resources Association*, 40(2), 503-522. <https://doi.org/10.1111/j.1752-1688.2004.tb01046.x>

Barredo, J. I. (2007). Major flood disasters in Europe: 1950–2005. *Natural Hazards*, 42(1), 125-148. <http://dx.doi.org/10.1007/s11069-006-9065-2>

Belmar, O., Velasco, J., & Martínez-Capel, F. (2011). Hydrological classification of natural flow regimes to support environmental flow assessments in intensively regulated Mediterranean rivers, Segura River Basin (Spain). *Environmental Management*, 47(5), 992. <https://doi.org/10.1007/s00267-011-9661-0>

Beven, K. J. (2011). *Rainfall-runoff modelling: the primer*. John Wiley & Sons.

Beven, K., & Binley, A. (1992). The future of distributed models: model calibration and uncertainty prediction. *Hydrological processes*, 6(3), 279-298. <https://doi.org/10.1002/hyp.3360060305>

Beven, K. J. & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Journal*, 24(1), 43-69. <https://doi.org/10.1080/02626667909491834>

Behzad, M., Asghari, K., Eazi, M., & Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with applications*, 36(4), 7624-7629. <https://doi.org/10.1016/j.eswa.2008.09.053>

Buisán, S. T., Earle, M. E., Collado, J. L., Kochendorfer, J., Alastrué, J., Wolff, M., ..., López-Moreno, J. I. (2017). Assessment of snowfall accumulation underestimation by tipping bucket gauges in the Spanish operational network. *Atmos. Meas. Tech.* 10(3), 1079-1091.

Burnash, R. J., Ferral, R. L., & McGuire, R. A. (1973). *A generalized streamflow simulation system, conceptual modeling for digital computers*. Report by the Joliet Federal State River Forecasts Center, Sacramento, CA.

Cambria, E., Huang, G. B., Kasun, L. L. C., Zhou, H., Vong, C. M., Lin, J., ... & Leung, V. C. (2013). Extreme learning machines [trends & controversies]. *IEEE Intelligent Systems*, 28(6), 30-59. <https://doi.org/10.1109/MIS.2013.140>

Cao, L. J., & Tay, F. E. H. (2003). Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on neural networks*, 14(6), 1506-1518. <https://doi.org/10.1109/TNN.2003.820556>

Centro de Estudios y Experimentación de Obras Públicas (CEDEX). (2011). *Mapa de caudales máximos. Memoria técnica*. España: MAPAMA. Disponible online: http://www.mapama.gob.es/es/agua/temas/gestion-de-los-riesgos-de-inundacion/memoria_tecnica_v2_junio2011_tcm30-214566.pdf (Último acceso: 23/4/2017)

- Chen, X. Y., & Chau, K. W. (2016). A hybrid double feedforward neural network for suspended sediment load estimation. *Water resources management*, 30(7), 2179-2194. <https://doi.org/10.1007/s11269-016-1281-2>
- Cibin, R., Sudheer, K. P., & Chaubey, I. (2010). Sensitivity and identifiability of stream flow generation parameters of the SWAT model. *Hydrological processes*, 24(9), 1133-1148. <https://doi.org/10.1002/hyp.7568>
- Coch, A., & Mediero, L. (2016). Trends in low flows in Spain in the period 1949–2009. *Hydrological Sciences Journal*, 61(3), 568-584. <https://doi.org/10.1080/02626667.2015.1081202>
- Collados-Lara, A.J., Pardo-Iguzquiza, E. & Pulido-Velazquez, D. (2018). Precipitation fields in an alpine Mediterranean catchment. Inversion of precipitation gradient with elevation or undercatch of snowfall?. *Int. J. Climatol.* DOI:10.1002/joc.5517.
- Conan, C., de Marsily, G., Bouraoui, F., & Bidoglio, G. (2003). A long-term hydrological modelling of the Upper Guadiana river basin (Spain). *Physics and Chemistry of the Earth, Parts A/B/C*, 28(4-5), 193-200. [https://doi.org/10.1016/S1474-7065\(03\)00025-1](https://doi.org/10.1016/S1474-7065(03)00025-1)
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Crawford, N. H. & Linsley, R. K. (1966). Digital simulation in hydrology: Stanford Watershed Model IV. *Tech. Rep. No. 39*, Stanford Univ., Palo Alto, Calif.
- Daniel, E. B., Camp, J. V., LeBoeuf, E. J., Penrod, J. R., Dobbins, J. P., & Abkowitz, M. D. (2011). Watershed modeling and its applications: A state-of-the-art review. *The Open Hydrology Journal*, 5(1). <http://dx.doi.org/10.2174/1874378101105010026>
- Dastorani, M. T., Koochi, J. S., Darani, H. S., Talebi, A., & Rahimian, M. H. (2013). River instantaneous peak flow estimation using daily flow data and machine-learning-based models. *Journal of Hydroinformatics*, 15(4), 1089-1098. DOI: 10.2166/hydro.2013.245
- Dastorani, M. T., Moghadamnia, A., Piri, J., & Rico-Ramirez, M. (2010). Application of ANN and ANFIS models for reconstructing missing flow data. *Environmental monitoring and assessment*, 166(1-4), 421-434. <https://doi.org/10.1007/s10661-009-1012-8>
- Dawson, C. W., & Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 43(1), 47-66. <https://doi.org/10.1080/02626669809492102>
- Demirel, M. C., Venancio, A., & Kahya, E. (2009). Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Advances in Engineering Software*, 40(7), 467-473. <https://doi.org/10.1016/j.advengsoft.2008.08.002>

- Deo, R. C., & Şahin, M. (2016). An extreme learning machine model for the simulation of monthly mean streamflow water level in eastern Queensland. *Environmental monitoring and assessment*, 188(2), 90. <https://doi.org/10.1007/s10661-016-5094-9>
- Ding, J., & Haberlandt, U. (2017). Estimation of instantaneous peak flow from maximum mean daily flow by regionalization of catchment model parameters. *Hydrological Processes*, 31(3), 612-626. <https://doi.org/10.1002/hyp.11053>
- Ding, J., Wallner, M., Müller, H., & Haberlandt, U. (2016). Estimation of instantaneous peak flows from maximum mean daily flows using the HBV hydrological model. *Hydrological Processes*, 30(9), 1431-1448. <https://doi.org/10.1002/hyp.10725>
- Eberhart, R., & Kennedy, J. (1995, October). A new optimizer using particle swarm theory. In *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on* (pp. 39-43). IEEE. <https://doi.org/10.1109/MHS.1995.494215>
- Emamgholizadeh, S., Moslemi, K., & Karami, G. (2014). Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). *Water resources management*, 28(15), 5433-5446. <https://doi.org/10.1007/s11269-014-0810-0>
- Fathzadeh, A., Jaydari, A., & Taghizadeh-Mehrjardi, R. (2017). Comparison of different methods for reconstruction of instantaneous peak flow data. *Intelligent Automation & Soft Computing*, 23(1), 41-49 <https://doi.org/10.1080/10798587.2015.1120991>
- Fekete, B. M., Vörösmarty, C. J., Roads, J. O., & Willmott, C. J. (2004). Uncertainties in precipitation and their impacts on runoff estimates. *Journal of Climate*, 17(2), 294-304. [https://doi.org/10.1175/1520-0442\(2004\)017<0294:UIPATI>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<0294:UIPATI>2.0.CO;2)
- Fill, H. D., & Steiner, A. A. (2003). Estimating instantaneous peak flow from mean daily flow data. *Journal of Hydrologic Engineering*, 8(6), 365-369. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(365\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(365))
- Firat, M., Turan, M. E., & Yurdusev, M. A. (2009). Comparative analysis of fuzzy inference systems for water consumption time series prediction. *Journal of hydrology*, 374(3-4), 235-241. <https://doi.org/10.1016/j.jhydrol.2009.06.013>
- Fuller, W. E. (1914). Flood flows. *Transactions of the American Society of Civil Engineers*, 77(1), 564-617.

Gassman, P. W., Reyes, M. R., Green, C. H., & Arnold, J. G. (2007). The soil and water assessment tool: historical development, applications, and future research directions. *Transactions of the ASABE*, 50(4), 1211-1250.

Gaume, E., Bain, V., Bernardara, P., Newinger, O., Barbuc, M., Bateman, A., ... & Daliakopoulos, I. (2009). A compilation of data on European flash floods. *Journal of Hydrology*, 367(1-2), 70-78. <https://doi.org/10.1016/j.jhydrol.2008.12.028>

Gholami, V., Chau, K. W., Fadaee, F., Torkaman, J., & Ghaffari, A. (2015). Modeling of groundwater level fluctuations using dendrochronology in alluvial aquifers. *Journal of hydrology*, 529, 1060-1069. <https://doi.org/10.1016/j.jhydrol.2015.09.028>

Goodison, B., Louie, P., Yang, D., 1998. *WMO solid precipitation measurement intercomparison final report*. WMO Tech. Document 872, World Meteorol. Organ., Geneva, Switzerland.

Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A comparative study of artificial neural networks, support vector machines and adaptive neuro fuzzy inference system for forecasting groundwater levels near Lake Okeechobee, Florida. *Water resources management*, 30(1), 375-391. <https://doi.org/10.1007/s11269-015-1167-8>

Gray, D. M. (1973). *Handbook of the principles of hydrology*, Water Information Center, Huntington, N.Y

Green, W.H. & Ampt, G.A. (1911). Studies on soil physics, 1. The flow of air and water through soils. *Journal of Agricultural Sciences* 4:11-24.

Groisman, P. Y., & Legates, D. R. (1994). The accuracy of United States precipitation data. *Bulletin of the American Meteorological Society*, 75(2), 215-227. [https://doi.org/10.1175/1520-0477\(1994\)075<0215:TAO USP>2.0.CO;2](https://doi.org/10.1175/1520-0477(1994)075<0215:TAO USP>2.0.CO;2)

Grusson, Y., Anctil, F., Sauvage, S., & Sánchez Pérez, J. M. (2017). Testing the SWAT Model with Gridded Weather Data of Different Spatial Resolutions. *Water*, 9(1), 54. <http://dx.doi.org/10.3390/w9010054>

Gupta, H. V., Sorooshian, S., & Yapo, P. O. (1999). Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. *Journal of Hydrologic Engineering*, 4(2), 135-143. [https://doi.org/10.1061/\(ASCE\)1084-0699\(1999\)4:2\(135\)](https://doi.org/10.1061/(ASCE)1084-0699(1999)4:2(135))

Hamaamin, Y. A., Nejadhashemi, A. P., Zhang, Z., Giri, S., & Woznicki, S. A. (2016). Bayesian Regression and Neuro-Fuzzy Methods Reliability Assessment for Estimating Streamflow. *Water*, 8(7), 287. <http://dx.doi.org/10.3390/w8070287>

- Hargreaves, G. L., Hargreaves, G. H., & Riley, J. P. (1985). Agricultural benefits for Senegal River basin. *Journal of irrigation and Drainage Engineering*, 111(2), 113-124. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1985\)111:2\(113\)](https://doi.org/10.1061/(ASCE)0733-9437(1985)111:2(113))
- Haykin S., 1999. *Neural networks: a comprehensive foundation*. Pearson Education, Hamilton, Ontario.
- Herrera, S., Gutiérrez, J. M., Ancell, R., Pons, M. R., Frías, M. D., & Fernández, J. (2012). Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over Spain (Spain02). *International Journal of Climatology*, 32(1), 74-85. <https://doi.org/10.1002/joc.2256>
- Herrero, J. & Polo, M. J. (2016). Evapsublimation from the snow in the Mediterranean mountains of Sierra Nevada (Spain). *Cryosphere*. 10, 2981-2998.
- Hirabayashi, Y., Kanae, S., Emori, S., Oki, T., & Kimoto, M. (2008). Global projections of changing risks of floods and droughts in a changing climate. *Hydrological Sciences Journal*, 53(4), 754-772. <https://doi.org/10.1623/hysj.53.4.754>
- Hock, R. (2003). Temperature index melt modelling in mountain areas. *Journal of hydrology*. 282, 104-115. [https://doi.org/10.1016/S0022-1694\(03\)00257-9](https://doi.org/10.1016/S0022-1694(03)00257-9)
- Hsu, K. L., Gupta, H. V., & Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water resources research*, 31(10), 2517-2530. <https://doi.org/10.1029/95WR01955>
- Huang, G. B. (2014). An insight into extreme learning machines: random neurons, random features and kernels. *Cognitive Computation*, 6(3), 376-390. <https://doi.org/10.1007/s12559-014-9255-2>
- Huang, G., Huang, G. B., Song, S., & You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61, 32-48. <https://doi.org/10.1016/j.neunet.2014.10.001>
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2004). Extreme learning machine: a new learning scheme of feedforward neural networks. In *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on* (Vol. 2, pp. 985-990). IEEE. <https://doi.org/10.1109/IJCNN.2004.1380068>
- Huang, G.B., Zhu, Q.Y., & Siew, C.K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70, 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Hydrologic Engineering Center (HEC). 1981. HEC-1, *Flood Hydrograph Package—User's Manual*. US Army Corps of Engineers: Davis, CA.

IGME. (2017). *Identificación y Caracterización de la Interrelación Que Se Presenta Entre Aguas Subterráneas, Cursos Fluviales, Descargas Por Manantiales, Zonas Húmedas y Otros Ecosistemas Naturales de Especial Interés Hídrico: 011 Miño-Sil*. Memoria Técnica (In Spanish). Available online: http://info.igme.es/SidPDF/146000/839/146839_0000001.pdf (accessed on 7 September 2017).

Irannezhad, M., Ronkanen A. K., Kløve, B. (2015). Effects of climate variability and change on snowpack hydrological processes in Finland. *Cold Regions Science and Technology*, 118, 14-29. <https://doi.org/10.1016/j.coldregions.2015.06.009>

Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685. <https://doi.org/10.1109/21.256541>

Jang, J. S. (1996). Input selection for ANFIS learning. In *Fuzzy Systems, 1996., Proceedings of the Fifth IEEE International Conference on* (Vol. 2, pp. 1493-1499). IEEE. <https://doi.org/10.1109/FUZZY.1996.552396>

Jang, J.S.R., & Gulley, N. (1995). *Fuzzy logic toolbox user's guide*. The Mathworks, Inc.: Natick, MA, USA.

Jang, J. S., & Sun, C. T. (1995). Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3), 378-406. <https://doi.org/10.1109/5.364486>

Jang, J. S. R., Sun, C. T., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*. Prentice-Hall, New Jersey, USA.

Jarvis, C.S. *Floods in United States*. In Water Supply Paper; US Geological Survey: Reston, VA, USA, 1936.

Jódar, J., Cabrera, J. A., Martos-Rosillo, S., Ruiz-Constán, A., González-Ramón, A., Lambán, L. J., ... & Custodio, E. (2017). Groundwater discharge in high-mountain watersheds: A valuable resource for downstream semi-arid zones. The case of the Bérchules River in Sierra Nevada (Southern Spain). *Science of the Total Environment*, 593, 760-772. <https://doi.org/10.1016/j.scitotenv.2017.03.190>

Jódar, A., Jiménez, P. (2016). *Influencia del cambio climático en el excedente de escorrentía de la Cuenca del Segura. Aproximación al caso de estudio mediante los modelos hidrológicos de Thornthwaite y Témez*. Desafíos del derecho de aguas: variables jurídicas, ambientales y de derecho comparado. Aranzadi. España. pp. 462-476.

- Kim, M., Baek, S., Ligaray, M., Pyo, J., Park, M., & Cho, K. H. (2015). Comparative studies of different imputation methods for recovering streamflow observation. *Water*, 7(12), 6847-6860. <http://dx.doi.org/10.3390/w7126663>
- Kim, J., & Kasabov, N. (1999). HyFIS: adaptive neuro-fuzzy inference systems and their application to nonlinear dynamical systems. *Neural Networks*, 12(9), 1301-1319. [https://doi.org/10.1016/S0893-6080\(99\)00067-2](https://doi.org/10.1016/S0893-6080(99)00067-2)
- Kiş, Ö. (2007). Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering*, 12(5), 532-539. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2007\)12:5\(532\)](https://doi.org/10.1061/(ASCE)1084-0699(2007)12:5(532))
- Knisel, W. G. (1980). *CREAMS: a field scale model for Chemicals, Runoff, and Erosion from Agricultural Management Systems [USA]*. United States. Dept. of Agriculture. Conservation research report (USA).
- Kottek, M., Grieser, J., Beck, C., Rudolf, B., & Rubel, F. (2006). World map of the Köppen-Geiger climate classification updated. *Meteorologische Zeitschrift*, 15(3), 259-263. <https://doi.org/10.1127/0941-2948/2006/0130>
- Krause, P., Boyle, D.P., & Bäse, F. (2005). Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5, 89-97.
- Krysanova, V., & White, M. (2015). Advances in water resources assessment with SWAT—an overview. *Hydrological Sciences Journal*, 60(5), 771-783. <https://doi.org/10.1080/02626667.2015.1029482>
- Kuczera, G., & Parent, E. (1998). Monte Carlo assessment of parameter uncertainty in conceptual catchment models: the Metropolis algorithm. *Journal of Hydrology*, 211(1-4), 69-85. [https://doi.org/10.1016/S0022-1694\(98\)00198-X](https://doi.org/10.1016/S0022-1694(98)00198-X)
- Kumar, M., Raghuvanshi, N. S., & Singh, R. (2009). Development and validation of GANN model for evapotranspiration estimation. *Journal of Hydrologic Engineering*, 14(2), 131-140. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2009\)14:2\(131\)](https://doi.org/10.1061/(ASCE)1084-0699(2009)14:2(131))
- Langbein, W.B. Peak discharge from daily records. *Water Resour. Bull.* 1944, 145.
- Lee, J. E., Heo, J. H., Lee, J., & Kim, N. W. (2017). Assessment of flood frequency alteration by dam construction via SWAT Simulation. *Water*, 9(4), 264. <http://dx.doi.org/10.3390/w9040264>
- Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics*, 2(2), 164-168.

Linsley, R. K., Kohler, M. A., & Paulhus, J. L. (1949). *Applied hydrology*. The McGraw-Hill Book Company, Inc.; New York.

Ma, L., Ascough II, J. C., Ahuja, L. R., Shaffer, M. J., Hanson, J. D., & Rojas, K. W. (2000). Root zone water quality model sensitivity analysis using Monte Carlo simulation. *Transactions of the ASAE*, 43(4), 883. doi: 10.13031/2013.2984

Madsen, H. (2000). Automatic calibration of a conceptual rainfall-runoff model using multiple objectives. *Journal of hydrology*, 235(3-4), 276-288. [https://doi.org/10.1016/S0022-1694\(00\)00279-1](https://doi.org/10.1016/S0022-1694(00)00279-1)

Maier, H. R., Jain, A., Dandy, G. C., & Sudheer, K. P. (2010). Methods used for the development of neural networks for the prediction of water resource variables in river systems: current status and future directions. *Environmental Modelling & Software*, 25(8), 891-909. <https://doi.org/10.1016/j.envsoft.2010.02.003>

Makwana, J. J., & Tiwari, M. K. (2017). Hydrological stream flow modelling using soil and water assessment tool (SWAT) and neural networks (NNs) for the Limkheda watershed, Gujarat, India. *Modeling Earth Systems and Environment*, 3(2), 635-645. <https://doi.org/10.1007/s40808-017-0323-y>

Malagò, A., Pagliero, L., Bouraoui, F., & Franchini, M. (2015). Comparing calibrated parameter sets of the SWAT model for the Scandinavian and Iberian peninsulas. *Hydrological Sciences Journal*, 60(5), 949-967. <https://doi.org/10.1080/02626667.2014.978332>

Mamdani, E.H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-machine Studies*, 7, 1-13.

Marco, J. B. (1993). The Segura River Basin Model. Disaggregation in a Semiarid Environment. In *Stochastic Hydrology and its Use in Water Resources Systems Simulation and Optimization* (pp. 413-423). Springer, Dordrecht.

Marquardt, D. W. (1963). An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, 11(2), 431-441.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133. <https://doi.org/10.1007/BF02478259>

Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente (20 de abril de 2018). *Gestión de los riesgos de inundación*. Recuperado de <http://www.mapama.gob.es/es/agua/temas/gestion-de-los-riesgos-de-inundacion/>

- Minns, A. W., & Hall, M. J. (1996). Artificial neural networks as rainfall-runoff models. *Hydrological sciences journal*, 41(3), 399-417. <https://doi.org/10.1080/02626669609491511>
- Misra, D., Oommen, T., Agarwal, A., Mishra, S.K., & Thompson, A.M. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 103, 527-535. <https://doi.org/10.1016/j.biosystemseng.2009.04.017>
- Molina-Navarro, E., Martínez-Pérez, S., Sastre-Merlín, A., & Bienes-Allas, R. (2014). Hydrologic modeling in a small Mediterranean basin as a tool to assess the feasibility of a limno-reservoir. *Journal of environmental quality*, 43(1), 121-131. doi:10.2134/jeq2011.0360
- Monteith, J.L. 1965. *Evaporation and the environment*. p. 205-234. In *The state and movement of water in living organisms*. 19th Symposia of the Society for Experimental Biology. Cambridge Univ. Press, London, U.K.
- Moral, F., Cruz-Sanjulián, J. J., & Olías, M. (2008). Geochemical evolution of groundwater in the carbonate aquifers of Sierra de Segura (Betic Cordillera, southern Spain). *Journal of hydrology*, 360(1-4), 281-296. <https://doi.org/10.1016/j.jhydrol.2008.07.012>
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900. doi: 10.13031/2013.23153
- Murillo, J. M., Navarro, J. A., 2011. Aplicación del modelo de Témez a la determinación de la aportación superficial y subterránea del sistema hidrológico Cornisa-Vega de Granada para su implementación en un modelo de uso conjunto. *Boletín Geológico y Minero*. 122 (3), 363-388. ISSN: 0366-0176.
- Mustafa, M. R., Isa, M. H., & Rezaur, R. B. (2012). Artificial neural networks modeling in water resources engineering: infrastructure and applications. *Int. J. Soc. Human Sci.*, 62, 341-349.
- Nachtergaele, F., van Velthuizen, H., Verelst, L., Batjes, N. H., Dijkshoorn, K., van Engelen, V. W. P., ... & Montanarella, L. (2010). The harmonized world soil database. In *Proceedings of the 19th World Congress of Soil Science, Soil Solutions for a Changing World*, Brisbane, Australia, 1-6 August 2010 (pp. 34-37).
- Nayebi, M., Khalili, D., Amin, S., & Zand-Parsa, S. (2006). Daily stream flow prediction capability of artificial neural networks as influenced by minimum air temperature data. *Biosystems engineering*, 95(4), 557-567. <https://doi.org/10.1016/j.biosystemseng.2006.08.012>

Neitsch, S. L., Arnold, J. G., Kiniry, J. R., & Williams, J. R. (2011). *Soil and water assessment tool theoretical documentation version 2009*. Texas Water Resources Institute.

Nguyen, H.T., Prasad, N.R., Walker, C.L. & Walker, E.A. (2003). *A First Course in Fuzzy and Neural Control*. Chapman & Hall/CRC Press, New York, USA.

Ochoa-Rivera, J. C., García-Bartual, R., & Andreu, J. (2002). Multivariate synthetic streamflow generation using a hybrid model based on artificial neural networks. *Hydrology and Earth System Sciences Discussions*, 6(4), 641-654.

Olyaie, E., Banejad, H., Chau, K. W., & Melesse, A. M. (2015). A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. *Environmental monitoring and assessment*, 187(4), 189. <https://doi.org/10.1007/s10661-015-4381-1>

Orden FOM/298/2016, de 15 de febrero, por la que se aprueba la norma 5.2 - IC drenaje superficial de la Instrucción de Carreteras. Boletín Oficial del Estado, núm. 60, de 10 de marzo de 2016, pp. 18882 a 19023. Recuperado de <https://www.boe.es/buscar/doc.php?id=BOE-A-2016-2405>

Organización Meteorológica Mundial (OMM). (2011). *Guía de prácticas hidrológicas. Vol II. Gestión de recursos hídricos y aplicación de prácticas hidrológicas* (6º ed.). Ginebra: Organización Meteorológica Mundial.

Pérez-Sánchez, J. ., Senent-Aparicio, J. ., Segura-Méndez, F. ., & Pulido-Velazquez, D. (2017). Evaluación de modelos de balance hidrológico concentrado en la España peninsular. *Hydrol. Earth Syst. Sci. Discuss* (under review), doi:10.5194/hess-2017-424.

Pfannerstill, M., Guse, B., y Fohrer, N. (2014). Smart low flow signature metrics for an improved overall performance evaluation of hydrological models. *Journal of hydrology*, 510, 447-458. <https://doi.org/10.1016/j.jhydrol.2013.12.044>

Priestley, C. H. B., & Taylor, R. J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly weather review*, 100(2), 81-92.

Qiu, L. J., Zheng, F. L., & Yin, R. S. (2012). SWAT-based runoff and sediment simulation in a small watershed, the loessial hilly-gullied region of China: capabilities and challenges. *International Journal of Sediment Research*, 27(2), 226-234. [https://doi.org/10.1016/S1001-6279\(12\)60030-4](https://doi.org/10.1016/S1001-6279(12)60030-4)

Rahman, K., Maringanti, C., Beniston, M., Widmer, F., Abbaspour, K., & Lehmann, A. (2013). Streamflow modeling in a highly managed mountainous glacier watershed using

- SWAT: the Upper Rhone River watershed case in Switzerland. *Water resources management*, 27(2), 323-339. <https://doi.org/10.1007/s11269-012-0188-9>
- Raposo, J. R., Dafonte, J., & Molinero, J. (2013). Assessing the impact of future climate change on groundwater recharge in Galicia-Costa, Spain. *Hydrogeology Journal*, 21(2), 459-479. <https://doi.org/10.1007/s10040-012-0922-7>
- Rezaei, H., Rahmati, M., & Modarress, H. (2017). Application of ANFIS and MLR models for prediction of methane adsorption on X and Y faujasite zeolites: effect of cations substitution. *Neural Computing and Applications*, 28(2), 301-312. <https://doi.org/10.1007/s00521-015-2057-y>
- Rezaie-Balf, M., & Kisi, O. (2017). New formulation for forecasting streamflow: evolutionary polynomial regression vs. extreme learning machine. *Hydrology Research*, nh2017283. DOI: 10.2166/nh.2017.283
- Rockwood D. M, Davis E.D., & Anderson J. A. (1972). *User Manual for COSSARR Model*. US Army Engineering Division, North Pacific: Portland,OR.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1985). *Learning internal representations by error propagation* (No. ICS-8506). California Univ San Diego La Jolla Inst for Cognitive Science.
- Sahuquillo, A., Cassiraga, E., Solera, A. and Murillo, J.M. (2011). *Modelos de uso conjunto de aguas superficiales y subterráneas*. Instituto Geológico y Minero de España. Madrid.
- Sangal, B. P. (1983). Practical method of estimating peak flow. *Journal of Hydraulic Engineering*, 109(4), 549-563. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1983\)109:4\(549\)](https://doi.org/10.1061/(ASCE)0733-9429(1983)109:4(549))
- Seckin, N. (2011). Modeling flood discharge at ungauged sites across Turkey using neuro-fuzzy and neural networks. *Journal of hydroinformatics*, 13(4), 842-849. doi: 10.2166/hydro.2010.046
- Senent-Aparicio, J., Perez-Sanchez, J., & Bielsa-Artero, A. M. (2016). Assessment of Sustainability in Semiarid Mediterranean Basins: Case Study of the Segura Basin, Spain. *TECNOLOGIA Y CIENCIAS DEL AGUA*, 7(2), 67-84.
- Senent-Aparicio, J., Pérez-Sánchez, J., Carrillo-García, J., & Soto, J. (2017). Using SWAT and fuzzy to assess the impact of climate change in the headwaters of the Segura river basin (SE Spain). *Water*, 9(2), 149. <http://dx.doi.org/10.3390/w9020149>
- Sevruk, B., 1982. *Methods of correction for systematic error in point precipitation measurement for operational use*. WMO Operational Hydrology Report No. 21, Geneva, Switzerland.

- Shabani, M., & Shabani, N. (2012). Application of artificial neural networks in instantaneous peak flow estimation for Kharestan Watershed, Iran. *Journal of resources and ecology*, 3(4), 379-383. <https://doi.org/10.5814/j.issn.1674-764x.2012.04.012>
- Shiau, J. T., & Hsu, H. T. (2016). Suitability of ANN-based daily streamflow extension models: a case study of Gaoping River basin, Taiwan. *Water resources management*, 30(4), 1499-1513. <https://doi.org/10.1007/s11269-016-1235-8>
- Shrestha, S., Shrestha, M., & Shrestha, P. K. (2017). Evaluation of the SWAT model performance for simulating river discharge in the Himalayan and tropical basins of Asia. *Hydrology Research*, nh2017189. DOI: 10.2166/nh.2017.189
- Shrestha, M., Wang, L., Koike, T., Tsutsui, H., Xue, Y., & Hirabayashi, Y. (2014). Correcting basin-scale snowfall in a mountainous basin using a distributed snowmelt model and remote-sensing data. *Hydrology and Earth System Sciences*, 18(2), 747-761. <https://doi.org/10.5194/hess-18-747-2014>
- Silva, E. A., & Tucci, C. E. (1998). Relacao entre as vazoes maximas diarias e instantaneas. *Revista Brasileira de Recursos Hidricos*, 3(1), 133-151.
- Simonovic, S. P. (2000). One view of the future. *Water International*, 25(1), 76-88. <https://doi.org/10.1080/02508060008686799>
- Singh, A., Imtiyaz, M., Isaac, R. K., & Denis, D. M. (2012). Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. *Agricultural Water Management*, 104, 113-120. <https://doi.org/10.1016/j.agwat.2011.12.005>
- Singh, V. P., & Woolhiser, D. A. (2002). Mathematical modeling of watershed hydrology. *Journal of hydrologic engineering*, 7(4), 270-292. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2002\)7:4\(270\)](https://doi.org/10.1061/(ASCE)1084-0699(2002)7:4(270))
- Sloan, P.G., Morre, I.D., Coltharp, G.B., & Eigel, J.D. (1983). *Modeling surface and subsurface stormflow on steeply-sloping forested watersheds*. Water Resources Inst. Report 142. Univ. Kentucky, Lexington.
- Soriano, G., & Samper, J. (2000). Monitoring and modelling water quantity and quality in a pilot catchment in North-western Spain. *Monitoring and modelling catchment water quantity and quality*, 83.
- Srivastava, P., McNair, J. N., & Johnson, T. E. (2006). Comparison of process-based and artificial neural network approaches for streamflow modeling in an agricultural

watershed. *JAWRA Journal of the American Water Resources Association*, 42(3), 545-563. <https://doi.org/10.1111/j.1752-1688.2006.tb04475.x>

Stisen, S., Højberg, A. L., Troldborg, L., Refsgaard, J. C., Christensen, B. S. B., Olsen, M., & Henriksen, H. J. (2012). On the importance of appropriate precipitation gauge catch correction for hydrological modelling at mid to high latitudes. *Hydrology and Earth System Sciences*, 16(11), 4157. DOI:10.5194/hess-16-4157-2012

Suárez, E. J. C. (2014). *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. UNED. Madrid.

Sudheer, K. P., Nayak, P. C., & Ramasastri, K. S. (2003). Improving peak flow estimates in artificial neural network river flow models. *Hydrological processes*, 17(3), 677-686. <https://doi.org/10.1002/hyp.5103>

Sugawara, M., Ozaki, E., Wantanabe, I., & Katsuyama, Y. (1976). Tank Model and its Application to Bird Creek, Wollombi Brook, Bihin River, Sanaga River, and Nam Mune. *National Center for Disaster Prevention, Tokyo, Research Note*, 11, 1-64.

Sugeno, M., & Kang, G.T. (1988). Structure identification of fuzzy model. *Fuzzy Sets and Systems*, 28, 15-33.

Sun, W., Ishidaira, H., Bastola, S., & Yu, J. (2015). Estimating daily time series of streamflow using hydrological model calibrated based on satellite observations of river water surface width: Toward real world applications. *Environmental research*, 139, 36-45. <https://doi.org/10.1016/j.envres.2015.01.002>

SWAT User's Manual, (2000). (Ultimo acceso 16 de mayo de 2018). <https://swat.tamu.edu/media/1290/swat2000theory.pdf>

Taguas, E. V., Ayuso, J. L., Pena, A., Yuan, Y., Sanchez, M. C., Giraldez, J. V., y Pérez, R. (2008). Testing the relationship between instantaneous peak flow and mean daily flow in a Mediterranean Area Southeast Spain. *Catena*, 75(2), 129-137. <https://doi.org/10.1016/j.catena.2008.04.015>

Takagi, T., & Sugeno, M. (1985). Identification of Systems and Its Applications to Modeling and Control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15, 116-132.

Talebizadeh, M., Morid, S., Ayyoubzadeh, S. A., & Ghasemzadeh, M. (2010). Uncertainty analysis in sediment load modeling using ANN and SWAT model. *Water Resources Management*, 24(9), 1747-1761. <https://doi.org/10.1007/s11269-009-9522-2>

Talebizadeh, M., & Moridnejad, A. (2011). Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models. *Expert Systems with Applications*, 38(4), 4126-4135. <https://doi.org/10.1016/j.eswa.2010.09.075>

Temez, J.R. (1977). *Modelo matemático de transformación precipitación aportación*. ASINEL. Asociación de Investigación Industrial Eléctrica, Madrid, Spain.

Todini, E. (1996). The ARNO rainfall—runoff model. *Journal of hydrology*, 175(1-4), 339-382. [https://doi.org/10.1016/S0022-1694\(96\)80016-3](https://doi.org/10.1016/S0022-1694(96)80016-3)

Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of clinical epidemiology*, 49(11), 1225-1231. [https://doi.org/10.1016/S0895-4356\(96\)00002-9](https://doi.org/10.1016/S0895-4356(96)00002-9)

Tucci, C. E. (1991). Regionalizaçao de vazoes no Rio Grande do Sul, IPH/UFRGS, Porto Alegre, Brazil (in Portuguese).

USD-SCS (1972). *National Engineering Handbook*. Section 4. Hydrology. Department of Agriculture. Soil Conservation Service. Washington.

Valery, A., Andréassian, V., Perrin, C., 2009. Inverting the hydrological cycle: when streamflow measurements help assess altitudinal precipitation gradients in mountain areas. *IAHS Publ.* 333, 281-285.

Van Griensven, A., & Meixner, T. (2006). Methods to quantify and identify the sources of uncertainty for river basin water quality models. *Water Science and Technology*, 53(1), 51-59. DOI: 10.2166/wst.2006.007

Vapnik, V.N. (1998). *The Nature of Statistical Learning Theory*. Springer, New York.

Wang, Y., Guo, S., Xiong, L., Liu, P., & Liu, D. (2015). Daily runoff forecasting model based on ANN and data preprocessing techniques. *Water*, 7(8), 4144-4160. <http://dx.doi.org/10.3390/w7084144>

Wang, G., Yang, H., Wang, L., Xu, Z., & Xue, B. (2014). Using the SWAT model to assess impacts of land use changes on runoff generation in headwaters. *Hydrological Processes*, 28(3), 1032-1042. <https://doi.org/10.1002/hyp.9645>

Williams J. R. & Hann R. W. (1973). *HYMO: Problem-Oriented Language for Hydrologic Modeling—User's Manual*. USDA: ARS-S-9.

Wu, C. L., Chau, K. W., & Li, Y. S. (2009). Predicting monthly streamflow using data-driven models coupled with data-preprocessing techniques. *Water Resources Research*, 45(8). <https://doi.org/10.1029/2007WR006737>

- Wu, J. S., Han, J., Annambhotla, S., & Bryant, S. (2005). Artificial neural networks for forecasting watershed runoff and stream flows. *Journal of hydrologic engineering*, 10(3), 216-222. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2005\)10:3\(216\)](https://doi.org/10.1061/(ASCE)1084-0699(2005)10:3(216))
- Yang, J. H., & Chang, C. C. (2008). Efficient residue number system iterative modular multiplication algorithm for fast modular exponentiation. *IET Computers & Digital Techniques*, 2(1), 1-5. <http://dx.doi.org/10.1049/iet-cdt:20070066>
- Yaseen, Z. M., El-Shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530, 829-844. <https://doi.org/10.1016/j.jhydrol.2015.10.038>
- Yang, D., Goodison, B. E., Metcalfe, J. R., Golubev, V. S., Elomaa, E., Gunther, T., ... & Copaciu, V. (1995). Accuracy of Tretyakov precipitation gauge: Result of WMO intercomparison. *Hydrological Processes*, 9(8), 877-895. <https://doi.org/10.1002/hyp.3360090805>
- Yang, J., Reichert, P., Abbaspour, K. C., Xia, J., & Yang, H. (2008). Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. *Journal of Hydrology*, 358(1-2), 1-23. <https://doi.org/10.1016/j.jhydrol.2008.05.012>
- Zhang, L., Jin, X., He, C., Zhang, B., Zhang, X., Li, J., ... & DeMarchi, C. (2016). Comparison of SWAT and DLBRM for hydrological modeling of a mountainous watershed in Arid Northwest China. *Journal of Hydrologic Engineering*, 21(5), 04016007. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001313](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001313)

APENDICE: CALIDAD DE LAS PUBLICACIONES

Publicación 1 y 2: Water




Water — Open Access Journal

Estadísticas Revista Water:

- ISSN: 2073-4441
- Fundada en 2009 (Volúmenes: 10)
- 3160 artículos publicados
- 1970 citas totales

Factor de impacto:

- Factor de impacto actual: **1,832**
- Factor de impacto de 5 años: **2,056**
- Rango de la categoría JCR 2016 : **34/88 (Q2) en "Water Resources"**



Publicación 3: Biosystems Engineering



Estadísticas Revista Biosystems Engineering

- ISSN: 1537-5110
- Fundada en 2002
- 4495 citas totales

Factor de impacto:

- Factor de impacto actual: **2,044**
- Factor de impacto de 5 años: **2,238**
- Rango de la categoría JCR 2016: **8/56 (Q1)** en “Agriculture, Multidisciplinary”

