

CONFIGURACIÓN EXPERIMENTAL DE UN PERCEPTRON MULTICAPA PARA LA MODELIZACIÓN DEL COMPORTAMIENTO DE LAS VARIABLES CLIMÁTICAS.

Labajo, A.L.*; Martín, Q.** y Labajo, J.L.*

*Departamento de Física General y de la Atmósfera. Universidad de Salamanca

**Departamento de Estadística. Universidad de Salamanca

RESUMEN

Se establece una metodología experimental para configurar los parámetros de un modelo de predicción de variables climáticas, basado en una red neuronal artificial (RNA) de tipo perceptron multicapa (Multilayer Perceptron, MLP). Para la configuración del modelo se emplean las series de datos pertenecientes a la red sinóptica y climatológica del Instituto Nacional de Meteorología (INM) de España. Para optimizar la topología de la red neuronal y su rendimiento se realiza un tratamiento de datos previo a la aplicación del modelo.

El modelo resultante se aplica a las series de datos de la variable temperatura mínima media mensual observadas en las estaciones de la red sinóptica y climatológica del INM en la meseta central española, proporcionando un alto grado de ajuste entre series reales y simuladas, según indican los valores de los coeficientes de determinación (R^2) y error cuadrático medio (MSE) y las gráficas de dispersión y secuencia de las series reales y simuladas.

Palabras clave: modelos de pronóstico, series climáticas, redes neuronales, perceptron multicapa, retropropagación.

INTRODUCCIÓN

La predicción del comportamiento del sistema climático ha constituido un campo de investigación que ha despertado un interés considerable en la comunidad científica, siendo ampliamente estudiado. El diagnóstico del comportamiento del sistema climático ha sido el objetivo de la investigación en las últimas décadas del siglo XX. Los modelos de diagnóstico del comportamiento de temperatura obtenidos [16] [8]

[9], han permitido la práctica confirmación del calentamiento global del planeta, y la diferenciación del comportamiento del clima en distintas regiones del mismo.

Los modelos de predicción de series temporales proporcionan valores futuros de la serie, a partir de los valores presentes y pasados. En estos modelos se pretende establecer la dinámica de un proceso observado a través del conjunto de datos, que constituye la serie temporal. Para ello el modelo ha de ser capaz de describir las relaciones subyacentes en las observaciones pasadas, para posteriormente extrapolar en el tiempo las series de datos [19] [10] [20]. Esta modelización es particularmente útil cuando exista alguna información disponible en los datos implicados en el proceso generador o cuando no hay un modelo que explique de forma satisfactoria la dinámica del proceso [20]. Las RNAs han sido sugeridas como una alternativa a los métodos estadísticos tradicionales en el campo de la predicción de series temporales [6] [20] [21]. Durante los últimos años se han comenzado a usar para desarrollar modelos de predicción de series temporales, en particular climáticas [17] [13] [2]. Frecuentemente las RNAs proporcionan resultados tan buenos, si no mejores que los métodos tradicionales de predicción, convirtiéndose en herramientas valiosas a añadir a los métodos estadísticos [12].

Se pueden encontrar metodologías diversas, en la que las RNAs se aplican a la predicción de series temporales climatológicas. Sin embargo los modelos RNAs también se han aplicado en otros campos como la ingeniería [18], la economía y el marketing [13], el reconocimiento de objetos [14] y rostros por ordenador [1], la medicina [15], etc.

Transformaciones, previas a la aplicación del modelo, de las series de trabajo pueden mejorar los resultados proporcionados por la RNA. Según Nelson *et al.* [12] los modelos RNAs, presentan resultados mejores al ser alimentados con las series desestacionalizadas. Según Zhang y Qi [21] las RNAs no son capaces de capturar variaciones estacionales y tendencias de forma efectiva, si no se realiza previamente un tratamiento de datos encaminado a lograr una serie estacionaria y desestacionalizada. Dorffner [5] también propone la desestacionalización de las series en una fase previa a la aplicación del modelo.

En este trabajo vamos a establecer las características de un RNA MLP, así como el tratamiento más efectivo de los datos, que permita un pronóstico en un paso de tiempo de la variable temperatura mínima media mensual.

En el Anexo se recogen las tablas que se citan en el texto.

METODOLOGÍA

Como base del modelo de pronóstico se empleó una RNA de tipo MLP adaptado de tres capas como el que se muestra en la figura 1. Se emplearon las funciones de activación tipo rampa en la capa de salida y tangente hiperbólica en las capas de entrada y oculta (figura 2). El modelo de pronóstico empleado fue un modelo de predicción en un paso de tiempo (figura 3), en el que la estimación en el instante de tiempo posterior se obtiene a partir de los valores anteriores de la serie de datos. Los patrones de entrenamiento y prueba fueron partes de la serie temporal, de la misma longitud y desfasados en un instante de tiempo. Se obtuvieron según el esquema que se muestra en la tabla 1. Esta configuración ha sido propuesta, entre otros, por Isasi y Galván [7].

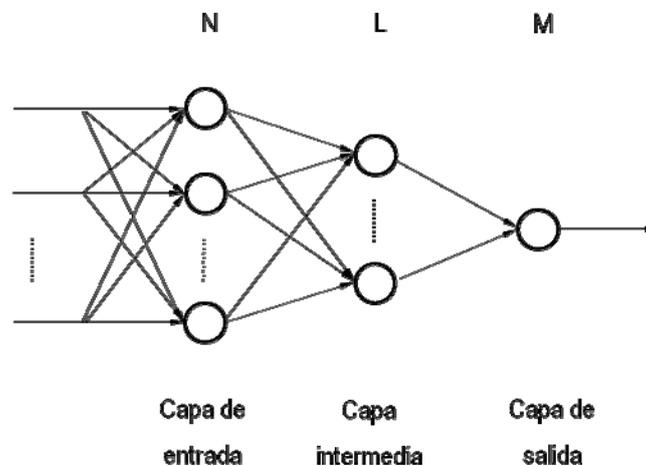


Figura 1. RNA MLP adaptada con tres capas de neuronas.

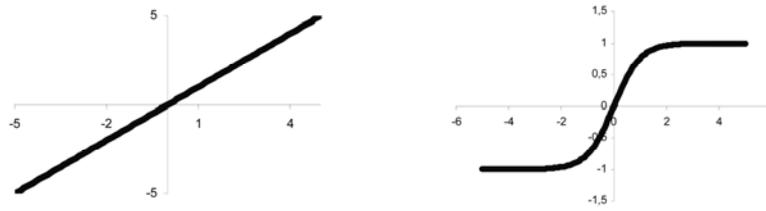


Figura 2. Funciones de activación rampa y tangente hiperbólica.

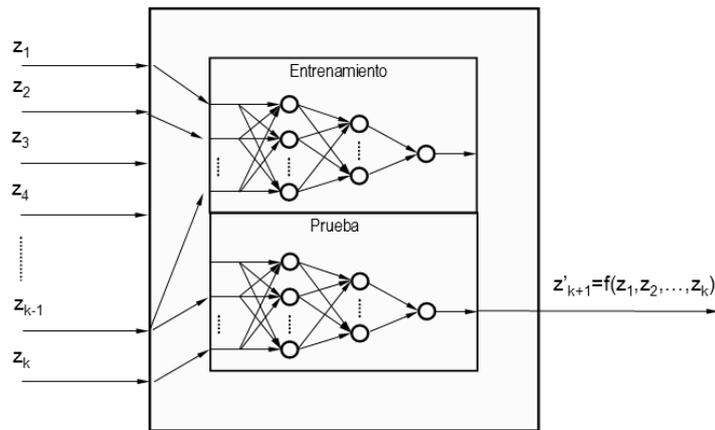


Figura 3. Esquema del modelo RNA de predicción de series temporales.

El modelo se aplica en las fases de entrenamiento y prueba. En la fase de entrenamiento la RNA se entrena con el algoritmo de retropropagación (Bakpropagation, BP) y algunas de sus variantes. En la etapa de prueba se valida el modelo a partir de los valores de R^2 y MSE entre series reales y simuladas y las correspondientes gráficas de secuencia y dispersión. En la figura 4 se muestra el esquema del proceso. El ajuste del modelo se realizó con las series de TminMed observadas en la estación meteorológica de Ávila y se partió de la configuración inicial que se muestra en la tabla 2.

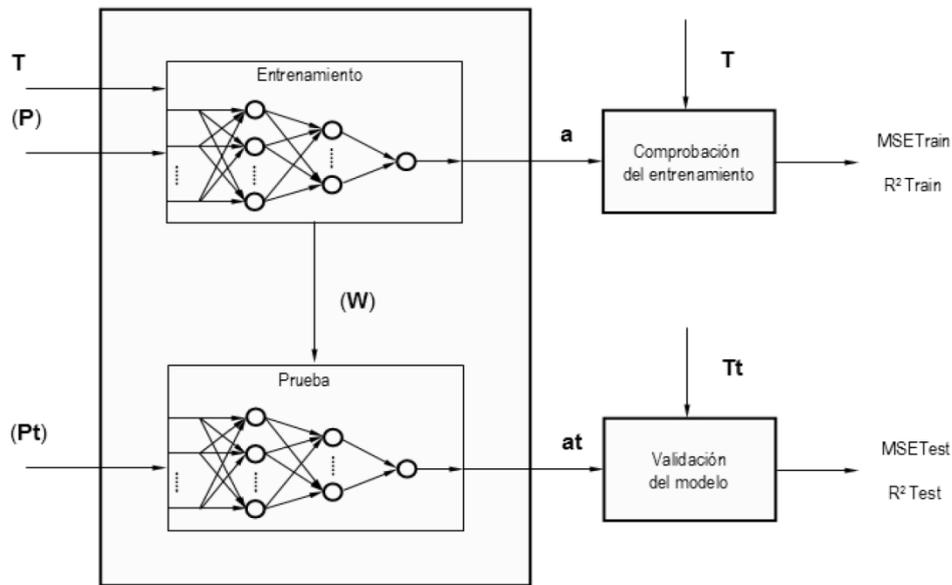


Figura 4. Modelo de pronóstico

Se determina experimentalmente aspectos como la longitud y número de patrones, funciones de activación por capas, tasa de entrenamiento y momento al usar el algoritmo BP, variantes del algoritmo BP, condición de fin de entrenamiento y número de neuronas de la capa oculta. Inicialmente el entrenamiento finaliza transcurridas 20.000 iteraciones del algoritmo. Posteriormente se añade una condición alternativa en cuanto al MSE entre series reales y simuladas en el entrenamiento para evitar un sobreentrenamiento del modelo. El valor de MSE fin de entrenamiento también se ajusta de forma experimental.

Finalizada la realización de este conjunto de experimentos se realizaron nuevos conjuntos de experimentos con el objetivo de determinar el procesamiento previo de los datos con los que el modelo proporciona mejores resultados. En estos experimentos el modelo fue alimentado por patrones de datos en los que la serie fue previamente procesada mediante diferenciación, desestacionalización, anomalías, normalización y estandarización. En estos experimentos también se configuró una nueva condición de MSE fin de entrenamiento para cada uno de los tratamientos considerados. Este tratamiento previo de los datos obligó a realizar una etapa posterior de tratamiento inverso de datos antes de poder validar los resultados, según se muestra en el esquema de la figura 5.

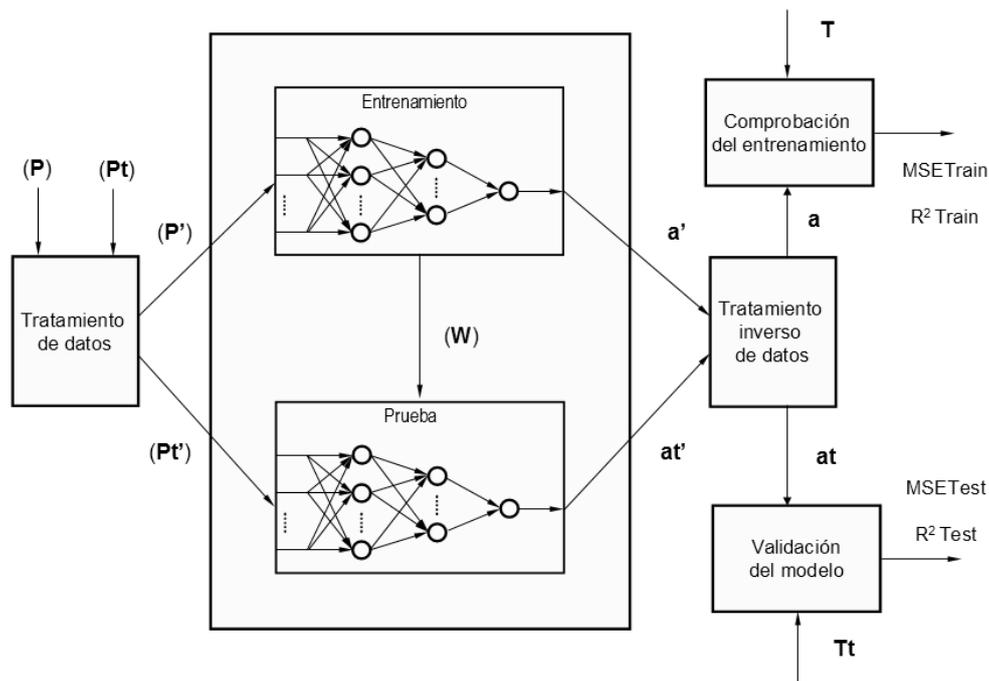


Figura 5. Modelo de pronóstico con preprocesamiento de las series de datos.

Una vez configurado el modelo se validó aplicándolo a las series de TminMed observadas en estaciones meteorológicas de la meseta central española.

DATOS

Las series de datos se han obtenido a partir de medidas diarias de la variable TminMed en una serie de observatorios de las redes sinóptica y climatológica del INM, en las comunidades autónomas de Castilla León y Castilla la Mancha (meseta central Española). Inicialmente los observatorios considerados han sido Ávila, Burgos, León, Palencia, Salamanca, Segovia, Soria, Valladolid, Villanubla (Valladolid) y Zamora en Castilla y León, y Albacete, Los Llanos (Albacete), Ciudad Real, Cuenca, Guadalajara y Toledo, en Castilla la Mancha.

Las series de datos se depuran aplicando un conjunto de filtros lógicos (limitar los valores más altos y más bajos, etc.), eliminando aquellos que aparezcan como claramente erróneos. Para una depuración más fina se han comparado todas las series entre sí para establecer aquellos casos en los que el dato de alguna de ellas difiera claramente del resto, lo que induce a pensar que es erróneo, aunque esté dentro de los límites que implican los filtros lógicos. A continuación se procede a rellenarlas

mediante técnicas de regresión lineal. Los valores de los coeficientes de determinación que se han obtenido en estas regresiones superan en casi todos los casos el valor 0,9, lo que garantiza la bondad del método. Se han desechado aquellas series que presentan más de un 20% de huecos. Esto obliga a no considerar las series de observaciones de Albacete y Palencia. A partir de las series rellenas se establecen las de valores medios mensuales. Se comprueba la homogeneidad de la varianza mediante el test de Levene [11].

Como consecuencia del análisis y tratamiento de los datos iniciales, las series definitivas de trabajo son las que corresponden a las observaciones de las estaciones meteorológicas de Ávila, Burgos, León, Salamanca, Segovia, Soria, Valladolid, Villanubla (Valladolid) y Zamora, en Castilla y León. En Castilla la Mancha los observatorios seleccionados son: Los Llanos (Albacete), Ciudad Real, Cuenca, Guadalajara y Toledo.

EL ALGORITMO DE RETROPROPAGACIÓN

El algoritmo de retropropagación (BP; Backpropagation) permite un aprendizaje supervisado por corrección del error de la capa de salida. Para ello el error producido en la capa de salida es realimentado hacia las capas anteriores de forma que los pesos son modificados en la dirección de gradiente negativo [4].

Corchado et al. [3] muestran el desarrollo del algoritmo completo y distinguen dos etapas en el aprendizaje. En la primera etapa, los patrones de datos de entrenamiento se presentan a la capa de entrada a la red. Estos datos se propagan desde la capa de entrada a la de salida, en la que se genera una salida de la RNA. En la segunda etapa, el resultado que proporciona la RNA se compara con el resultado esperado para cada uno de los patrones de entrenamiento. Si no coinciden, el error se utiliza para modificar los pesos de las capas intermedias. El hecho de que el error se propague desde la capa de salida a la entrada proporciona el nombre al algoritmo.

La regla de actualización se expresa de la siguiente forma:

$$w_{ik}(t+1) = w_{ik}(t) + \Delta_p w_{ik}(t) + \mu(w_{ik}(t) - w_{ik}(t-1))$$

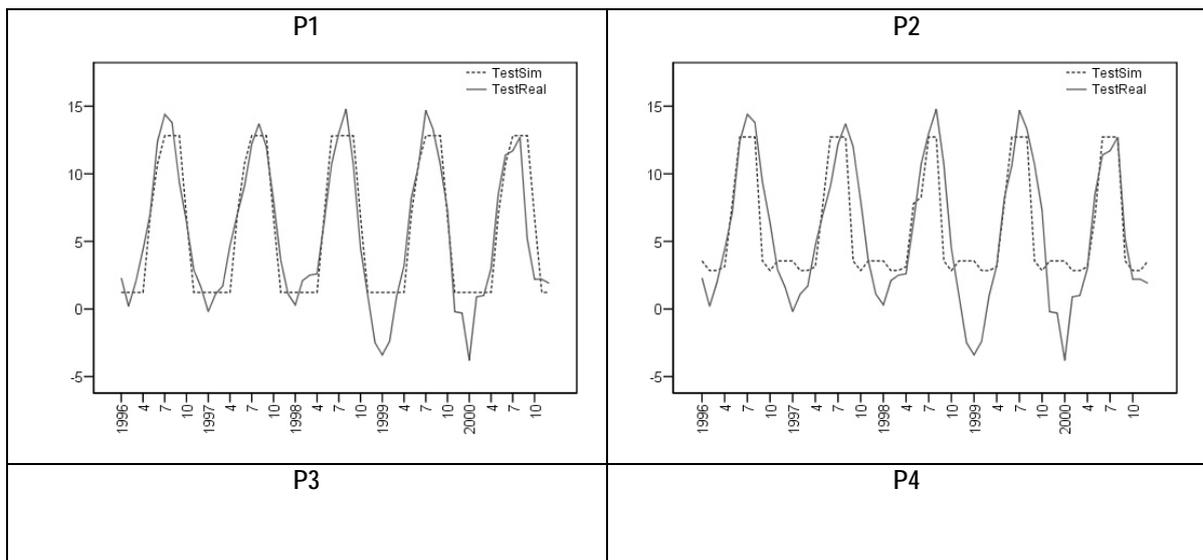
$$\Delta_p w_{ik} = -\eta \frac{\partial E^p}{\partial w_{ik}}, \quad E^p = \frac{1}{2} \sum_{k=1}^M (a_k^p - y_k^p)^2$$

$$\vec{x}^p = (x_1^p, x_2^p, \dots, x_N^p)^T, \quad \vec{a}^p = (a_1^p, a_2^p, \dots, a_M^p)^T$$

Donde w_{ik} es el peso asociado a la conexión entre la neurona i -ésima de una capa y la k -ésima de la siguiente, E^p es la función de error, \vec{x}^p el p -ésimo vector de entrada a la red, \vec{a}^p el p -ésimo vector de salida esperado, η la tasa de entrenamiento y μ el momento.

CONFIGURACIÓN DEL MODELO

Los experimentos de configuración del modelo se agrupan según los parámetros que se pretenden ajustar, dando lugar a distintos conjuntos de experimentos. A cada experimento se le ha asignado una referencia por una mayor claridad en la exposición de los resultados. Se muestran las tablas de resultados, con los correspondientes valores de R^2 y MSE en las fases de entrenamiento y prueba, agrupadas también por conjuntos de experimentos. Igualmente las figuras 7 a 9 muestran las gráficas de secuencias correspondientes a las etapas de validación del modelo. En las gráficas de secuencia se ha representado la temperatura ($^{\circ}\text{C}$) frente la fecha (mes y año). La línea continua representa la secuencia real (TestReal) y la discontinua la simulada por el modelo (TestSim).



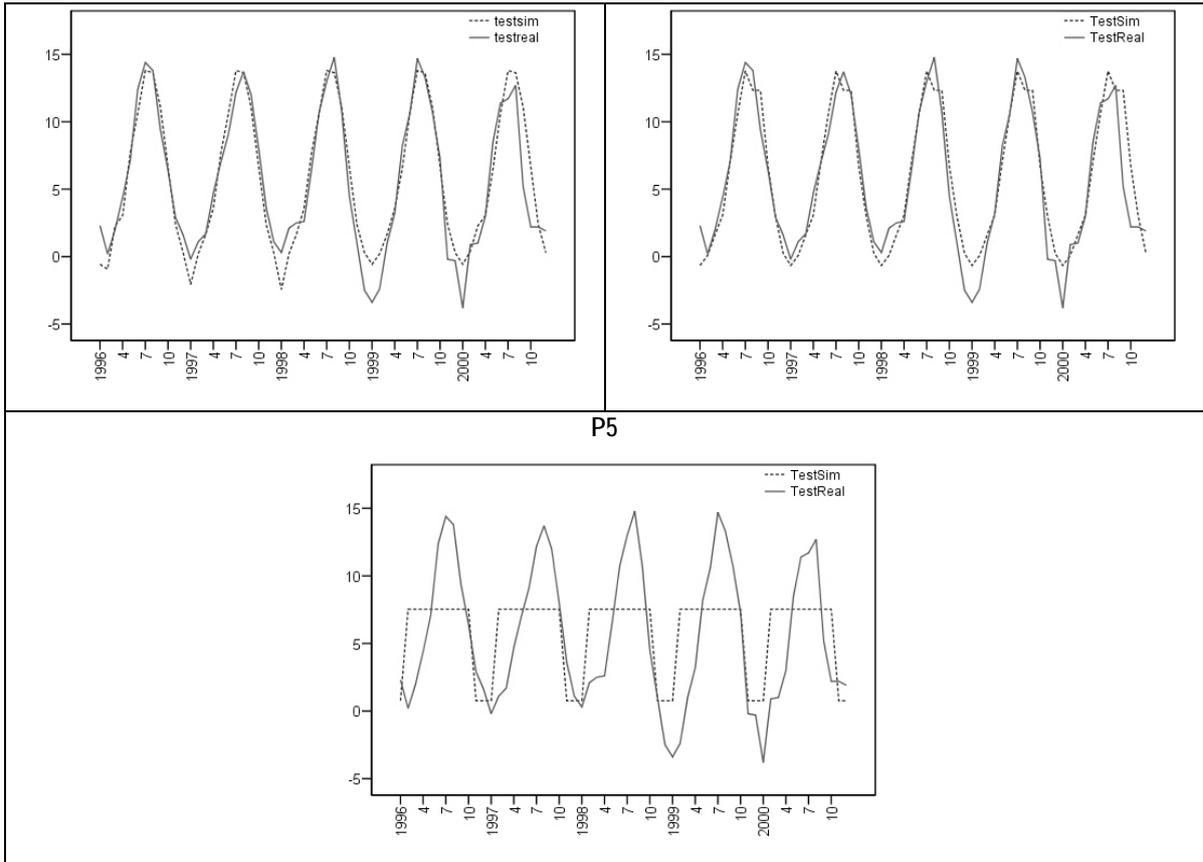
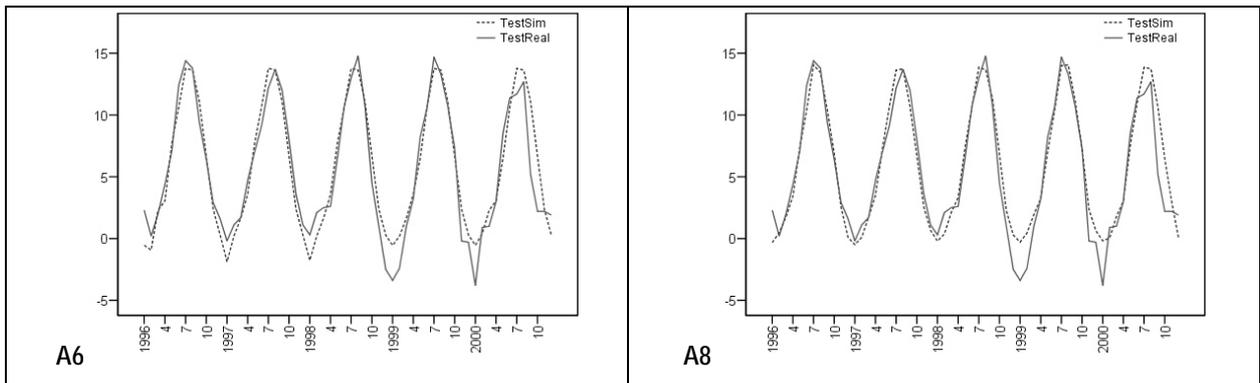


Figura 7. Evolución temporal de las series reales TminMed (°C) y simuladas con la RNA para los tipos de patrones correspondientes a los experimentos P.



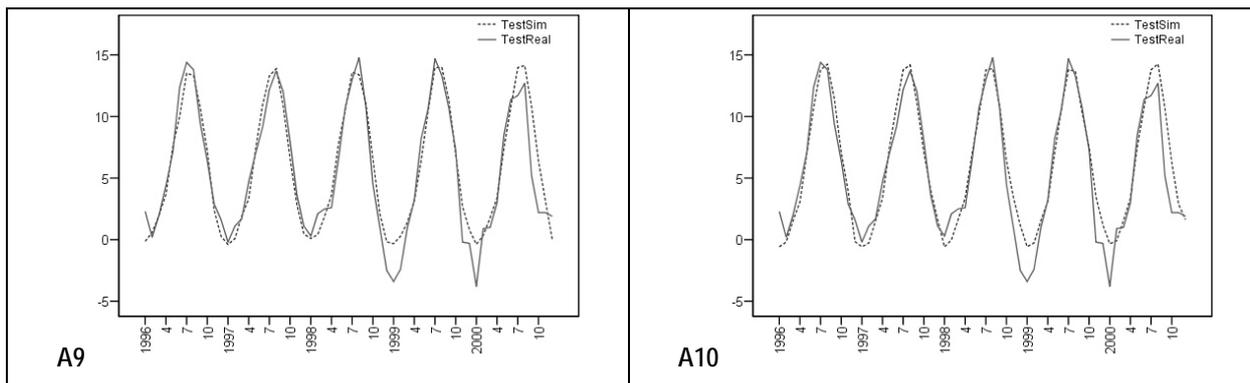


Figura 8. Evolución temporal de las series reales TminMed (°C) y simuladas con la RNA para los tipos de patrones correspondientes a los experimentos A.

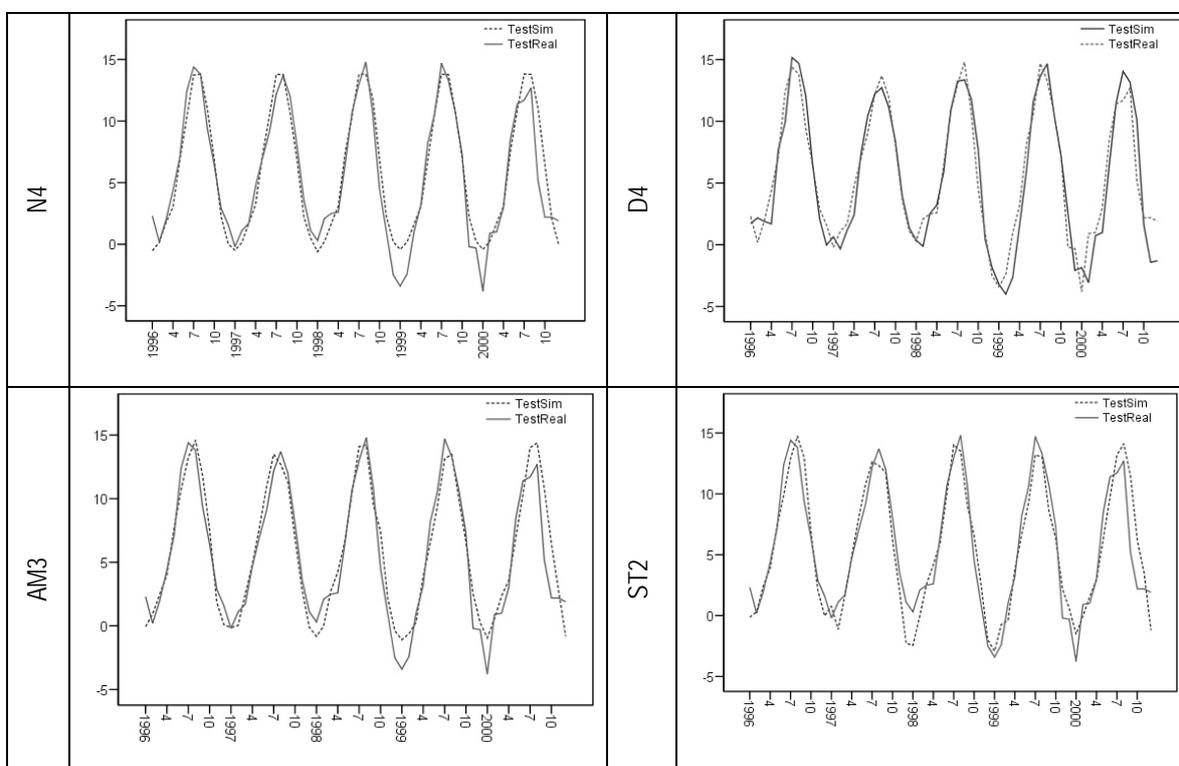


Figura 9. Gráficas de secuencia entre las series reales y las simuladas por el modelo para la etapa de entrenamiento, correspondientes a los experimentos que mejores resultados presentaban para cada transformación de datos.

El conjunto de experimentos P se encaminan a configurar la longitud de los patrones (N), el número de patrones de entrenamiento (NTr) y el número de patrones de prueba (NTe). En los experimentos N varía entre 60 y 180, ajustando en todos los casos el número de patrones de prueba a 60 para hacer posible la comparación entre los distintos casos. Los resultados obtenidos se muestran en la tabla 3 y la figura 7. Los experimentos que mejores resultados proporcionan son el P3 y P4, correspondientes a 120 y 96 datos por patrón respectivamente. En los experimentos P1, P2 y P5 el modelo

presenta una limitación importante de ajuste de los valores extremos de la serie real. Esta limitación se hace más evidente en el caso del experimento P5. Los experimentos P3 y P4, con patrones de longitud 10 y 8 años respectivamente son los que mejores resultados presentan, siendo ligeramente mejores los del experimento P3.

A continuación se realiza el conjunto de experimentos A, cuyo objetivo es determinar el algoritmo de entrenamiento con el que el modelo proporciona mejores resultados, de entre el BP estándar y sus variantes. En los experimentos A1 a A5 el algoritmo se entrenó durante 20.000 iteraciones, valor que se consideró lo suficientemente grande como para conseguir un grado de ajuste muy elevado entre las series reales y simuladas en la fase de entrenamiento. Los resultados obtenidos se muestran en la tabla 4. En algunos casos se obtiene un entrenamiento casi perfecto, situación que no se mantiene en la fase de prueba. Por lo tanto se deja constancia de un problema de sobre-entrenamiento. En la fase de prueba el algoritmo con el que se obtiene mejores resultados es el algoritmo BP estándar. Como consecuencia del sobre-entrenamiento se realizó un conjunto de experimentos posteriores, A6 a A10, en los que se añade una condición alternativa de fin de entrenamiento al alcanzar un valor de MSE de 1,5 entre las series reales y las simuladas en la fase de entrenamiento. Los resultados de experimentos desarrollados se muestran en la tabla 5 y la figura 8 y confirman el fenómeno de sobre-entrenamiento y como los mejores resultados en el entrenamiento no se corresponden con los mejores resultados en la prueba. Para los experimentos A6 a A10, el algoritmo que proporciona mejores resultados es el BP de tasa de entrenamiento variable.

Los experimentos anteriores sugieren la necesidad de realizar un ajuste experimental de la condición de MSE de fin de entrenamiento. Estos experimentos se nombraron como conjunto M. La tabla 6 muestra los valores de R^2 y MSE correspondientes. El experimento que presenta resultados algo mejores es el M2.

De igual forma se procede para realizar el ajuste del número de neuronas de la capa oculta, que constituye el conjunto de experimentos N. Como en los casos anteriores los resultados se muestran en la tabla 7. Se observa como los mejores resultados se obtienen con el experimento N3 que se corresponde con 60 neuronas en la capa oculta.

TRATAMIENTO PREVIO DE LOS DATOS

A continuación el modelo es alimentado con datos previamente tratados de alguna de las formas explicadas en la metodología. La aplicación del modelo según los distintos procesamientos previos de los datos constituyen nuevos conjuntos de experimentos en los que, además, se realiza un nuevo ajuste de la condición de MSE fin de entrenamiento. Se emplean, como en el caso anterior, las series de TminMed obtenidas en la estación meteorológica de Ávila en el periodo comprendido entre enero de 1945 y diciembre de 2000.

En las tablas 8 a14 se muestran los resultados correspondientes a los experimentos de ajuste de MSE fin de entrenamiento para los preprocesamientos de datos de diferenciación (tabla 8), desestacionalización (tabla 9), diferenciación y desestacionalización (tabla 10), anomalías por patrón (tabla 11), normalización (tabla 12), anomalías mensuales (tabla 13), y estandarización (tabla 14). Las referencias empleadas para los experimentos, según los distintos tipos de preprocesamiento de datos, son D (diferenciación), Ds (desestacionalización), DsD (diferenciación y desestacionalización), AP (anomalías por patrón), NR (normalización), AM (anomalías mensuales) y ST (estandarización).

Para una mayor claridad en la exposición de los resultados, en la tabla 15 se muestran los resultados del mejor experimento de cada conjunto correspondiente a un preprocesamiento de datos distinto. Estos experimentos muestran el valor del MSE fin de entrenamiento ajustado para cada procesamiento de datos previo considerado. En las figuras 9 y 10 se muestran las gráficas de secuencia y dispersión, correspondientes a la etapa de prueba, de los experimentos que consideramos más significativos entre los que se muestran en la tabla 15.

En la fase de entrenamiento, los valores de R^2 y MSE indican un grado de ajuste muy elevado entre la serie simulada por el modelo y la real cuando se alimenta con patrones de entrenamiento constituidos por datos tratados de cualquiera de las formas descritas. Este grado de ajuste disminuye, en todos los casos, para las series simuladas y reales correspondientes a la etapa de validación del modelo RNA. La disminución más significativa se produce para el experimento NR4, correspondiente a la transformación de normalización. En este caso el modelo no ajusta las series correspondientes de forma adecuada.

Los experimentos D4 y AP3 (tratamientos de diferenciación y anomalías por patrón respectivamente) son los que presentan mejores resultados, en cuanto a R^2 y MSE, en la etapa de prueba. El experimento D4 proporciona un valor de coeficiente de determinación de 0,908, mientras que el AP3 presenta un valor de 0,915, ligeramente mejor. En cuanto al MSE también es ligeramente mejor el del experimento AP3 (2,63), aunque el del experimento D4 es prácticamente igual (2,68).

En la figura 9 se presentan los gráficos de secuencia, para la prueba del modelo, de los experimentos seleccionados. Se puede observar en las gráficas de secuencia como en los experimentos N4, AP3 y AM3 las series simuladas presentan ciclos muy similares de unos años a otros, por lo que el modelo no es capaz de ajustar las variaciones de los valores extremos de la serie. La secuencia simulada correspondiente al experimento ST2 si presenta variaciones entre valores extremos de unos ciclos a otros, aunque estas variaciones difieren de los de la serie real. La secuencia de la serie simulada del experimento NR4 demuestra un mal ajuste con la serie real. Los experimentos D4 y DsD7 son los que presentan un ajuste mejor entre series reales y simuladas. En ambos casos el modelo parece ajustarse bastante bien en los meses de invierno de 1999 y 2000, aunque no ajustan del todo bien en los meses de verano de 2000. Sin embargo el experimento D4 parece ajustar algo mejor este periodo.

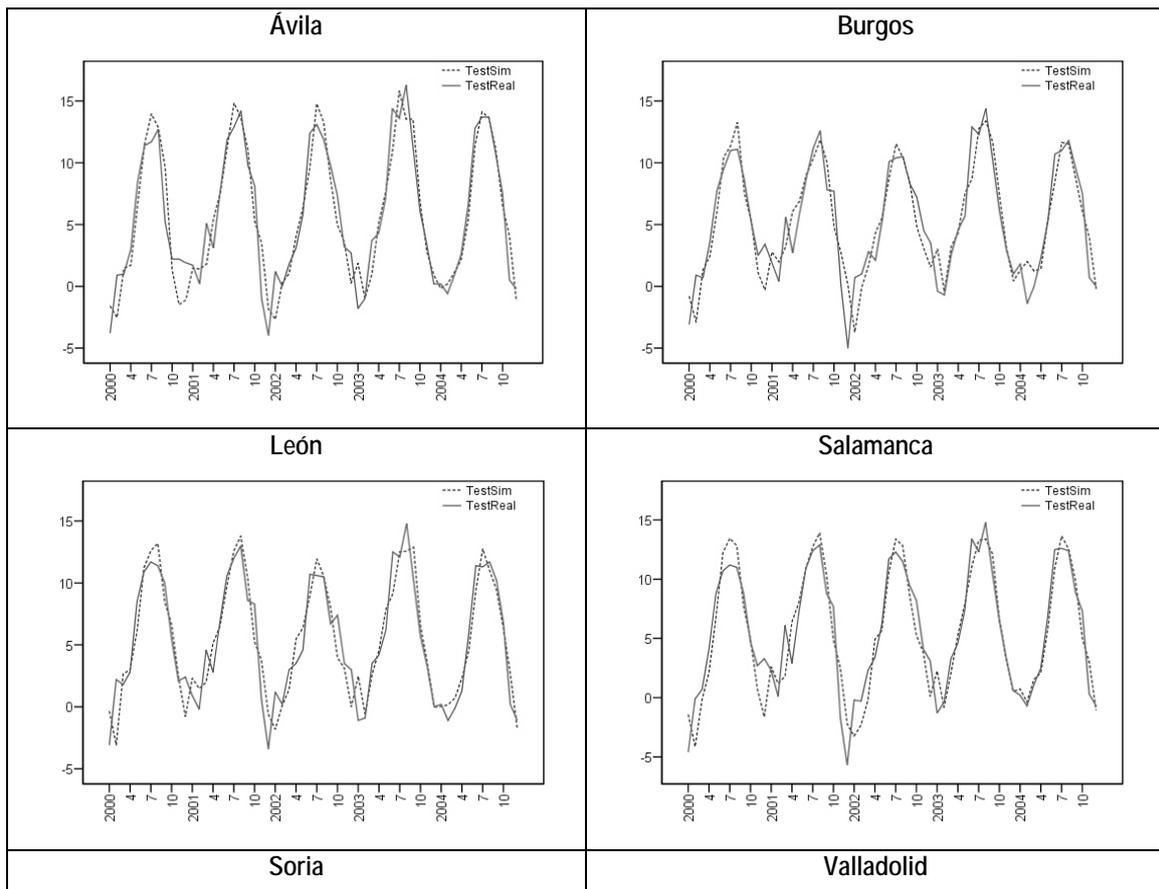
Los gráficos de dispersión entre las series reales y simuladas en la etapa de entrenamiento (figura 10) por el modelo RNA, muestran que el único experimento en el que no se aprecia un efecto de agrupación de datos es el D4, correspondiente a la diferenciación de la serie. En el experimento DsD7 parece observarse dos grupos de datos, aunque esta agrupación no es evidente. Además en este caso la nube de puntos parece ser algo menos dispersa que la del experimento D4. El experimento NR4 presenta un efecto de apertura de la nube de puntos según aumenta el valor de los datos, lo que supone que la RNA ajusta, en el entrenamiento, peor los datos de mayor valor. El resto de experimentos presentan, en mayor o menor medida, el efecto de agrupación de datos, ya que se observan varias nubes de puntos en torno a la recta de regresión. Este efecto supone que el modelo proporciona salidas correspondientes a los grupos de datos, y parece no es capaz de proporcionar salidas entre los grupos. Este efecto de agrupación se observa claramente en torno a los valores mayores (meses de verano) y a los valores

menores (meses de invierno), lo que provoca desajustes entre las series reales y las simuladas por el modelo RNA.

RESULTADOS

Para comprobar las capacidades del modelo de pronóstico desarrollado, se aplicó a las series de TminMed observadas en estaciones de la meseta central española. El periodo de estudio se amplió hasta diciembre de 2004, gracias a la disponibilidad de datos en el momento en que se realizó el citado estudio.

Al igual que en los apartados anteriores se muestran las tablas de resultados y las gráficas de secuencia correspondientes. Para Castilla y León los resultados se muestran en la tabla 16 y la figura 11. Para Castilla la Mancha en la tabla 17 y la figura 12.



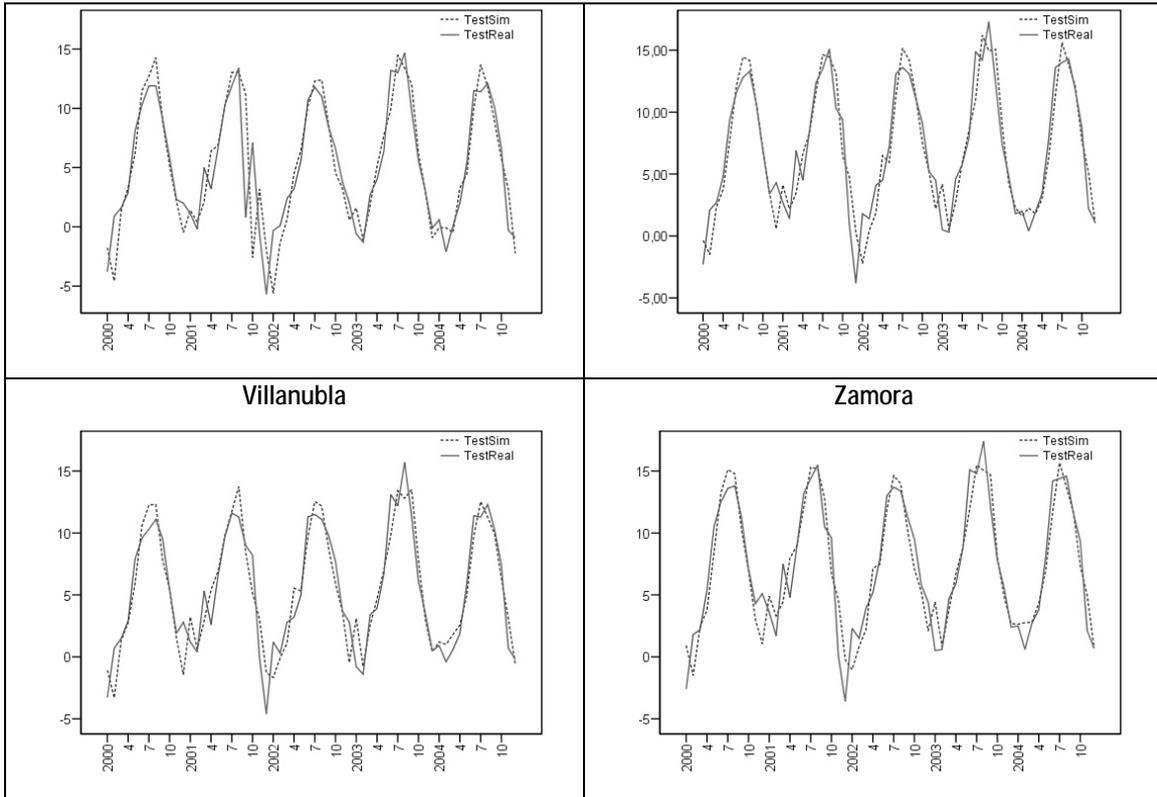
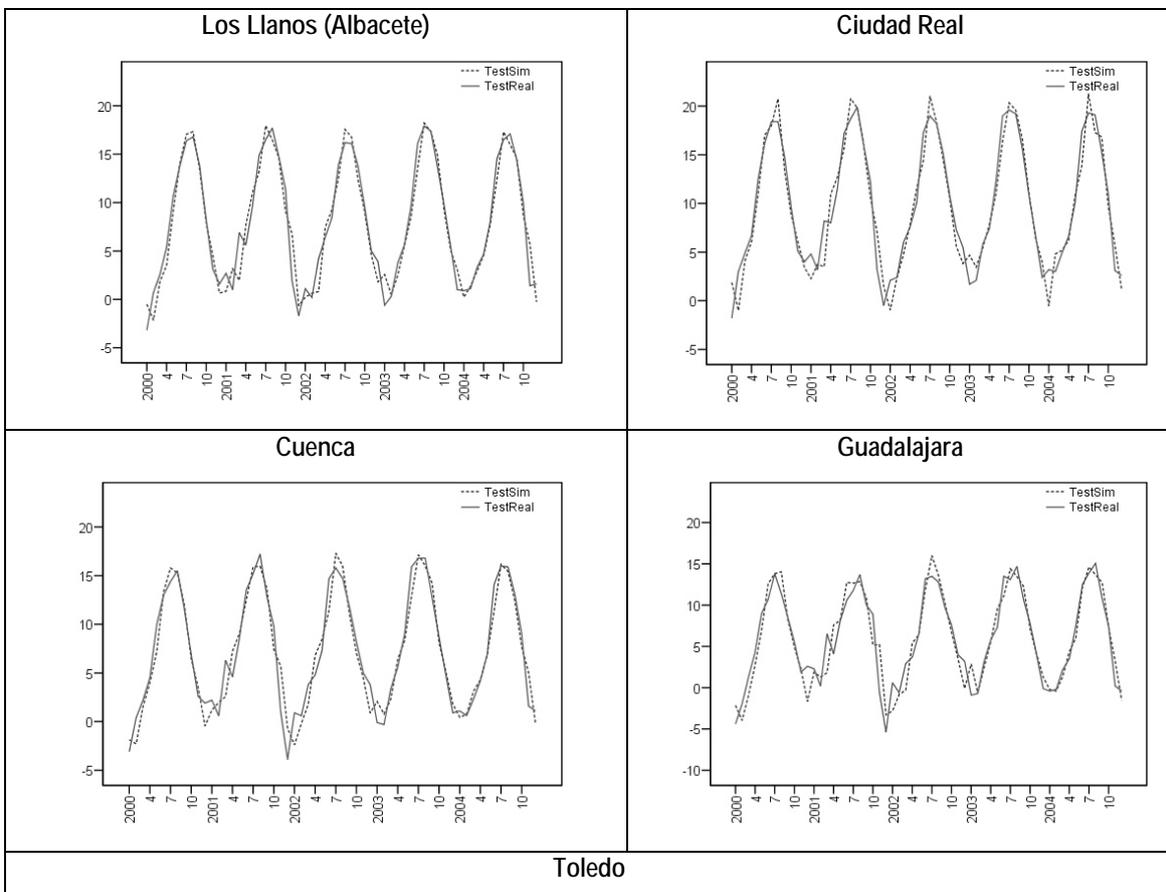


Figura 11. Gráficas de secuencia de las series reales (TestReal) y simuladas (TestSim) correspondientes a la aplicación del modelo local a las series de TminMed (°C) observadas en estaciones de Castilla y León.



Toledo

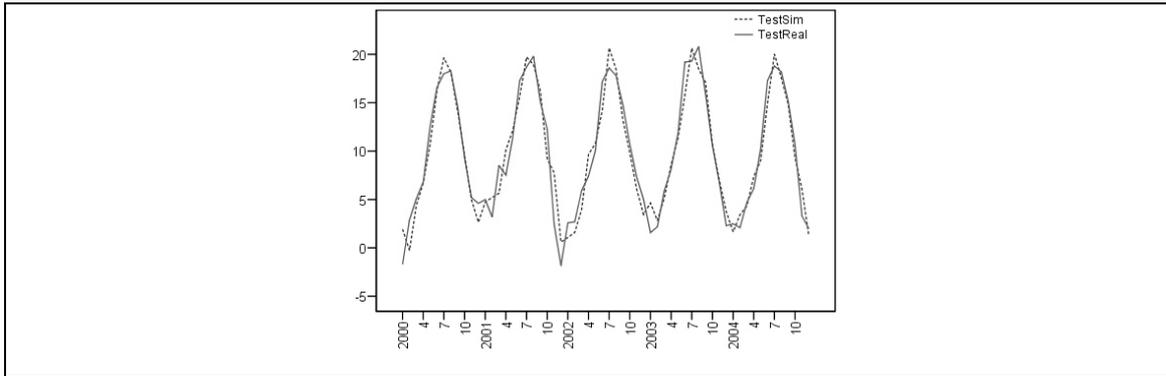


Figura 12. Gráficas de secuencia de las series reales (TestReal) y simuladas (TestSim) correspondientes a la aplicación del modelo local a las series de TminMed (°C) observadas en estaciones de Castilla y León.

Los valores de R^2 y MSE de las tablas 16 y 17 demuestran, en general, un ajuste mejor entre series reales y simuladas en la fase de entrenamiento frente a la de prueba o validación del modelo. También demuestran un alto grado de concordancia entre series reales y simuladas en la fase de prueba en prácticamente todos los casos, siendo en algunos casos este ajuste muy elevado, como en todas las estaciones de Castilla la Mancha, con la excepción de Guadalajara. La aplicación del modelo a las series de datos observadas en Castilla la Mancha presenta resultados algo mejores, exceptuando también el caso de Guadalajara, que los casos correspondientes de Castilla y León.

Las gráficas de secuencia, que se muestran en las figuras 11 y 12, dejan constancia de un alto grado de concordancia entre las series de valores reales y previstos por el modelo, prácticamente en todos los casos. Las series de valores reales y de valores simulados por el modelo presentan las mismas características generales de evolución y tendencia.

CONCLUSIONES

La metodología experimental desarrollada para el ajuste de la RNA MLP ha demostrado su eficacia en el diseño del modelo, si bien esta metodología no tiene porque ser única. La RNA MLP adaptada para este trabajo, de tres capas y con funciones de activación como las descritas, demuestra su capacidad para modelizar de forma no lineal los valores futuros de una serie temporal del tipo de las consideradas en este trabajo, a partir únicamente de valores pasados de la misma serie temporal.

La aplicación del modelo RNA a los datos de las series de trabajo presenta un efecto de agrupación de los valores de salida del modelo RNA, efecto que se acentúa en

los valores extremos y que se observa con facilidad en las gráficas de dispersión correspondientes. Este efecto se traduce en que los valores extremos de la serie simulada por el modelo RNA varían muy poco a lo largo del tiempo. Este efecto se modifica en función de los tratamientos previos de las series de trabajo.

La realización de un tratamiento previo de los datos diferenciando, desestacionalizando, diferenciando y desestacionalizando, la serie o realizando una transformación de anomalías por patrón, reduce el efecto de agrupación de valores de salida y mejora los resultados proporcionados por el modelo. El tratamiento de datos que minimiza este efecto es el correspondiente a la diferenciación de la serie. Además, el tratamiento de diferenciación de las series es con el que se obtiene un mejor ajuste de los valores extremos y, también, de las características de evolución temporal y tendencia.

Las series simuladas (previstas) por la RNA presentan una concordancia muy elevada con las reales, tanto en la fase de entrenamiento como en la de prueba. El ajuste entre las series simuladas y reales en la fase de entrenamiento es mejor, como parece lógico, que el ajuste de las correspondientes series de la etapa de validación.

La capacidad predictora del modelo RNA se pone de manifiesto en el hecho de que las series simuladas por el modelo, en la fase de prueba, mantienen las mismas características generales de evolución y tendencia que las series reales. En general el modelo RNA es capaz de ajustar las variaciones en los valores extremos que presentan las series de datos observadas. Además el modelo es capaz de ajustar algunas variaciones en las series reales, que parecen anomalías al comparar con la evolución temporal de la serie en periodos anteriores.

La aplicación del modelo RNA a series que presentan una variabilidad mayor, como las series correspondientes a estaciones de Castilla y León proporciona peores resultados que en los casos en que se aplica a series cuya variabilidad es menor, como las series correspondientes a Castilla la Mancha.

AGRADECIMIENTOS

Este trabajo ha sido realizado en el marco del proyecto de investigación CGL2009-08565. Agradecemos al Instituto Nacional de Meteorología las facilidades dadas para la obtención de los datos, que han sido imprescindibles para la realización del mismo.

BIBLIOGRAFÍA

- [1] CABELLO PARDOS E., SÁNCHEZ SÁNCHEZ A., LABAJO IZQUIERDO A. L., PASTOR PÉREZ L. y ALONSO MORENO J. (1998). Supervised methods for face recognition using geometric characteristics. Proceedings of the IASTED International Conference. Signal Processing and Communications. 261-264.
- [2] CANNON A. J y McKENDRY I. G. (2002). A graphical sensitivity analysis for statistical climate models: application to Indian monsoon rainfall prediction by artificial neural networks and multiple linear regression models. *International Journal of Climatology*, **22**: 1687-1708.
- [3] CORCHADO J. M., DÍAZ F., BORRAJO L. FERNÁNDEZ F. (2000). *Redes Neuronales Artificiales. Un enfoque práctico*. Servicio de Publicacións da Universidade de Vigo.
- [4] DEMUTH H y BEALE M. (2000). Neural Network Toolbox. *User's Guide*. (Version 4). Available in http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf
- [5] DORFFNER, G. (1996). Neural Networks for Time Series Processing. *Neural Network World*, **4**: 447-468.
- [6] GARDNER M. W. and DORLING S. R.. (1998). Artificial Neural Networks (The Multilayer Perceptron)- *Atmospheric Environment*, **32** (14). 2627-2636.
- [7] ISASI VIÑUELA P. y GALVÁN LEÓN I. M. (2004). *Redes de neuronas artificiales. Un enfoque práctico*. Pearson Educación.
- [8] LABAJO, J.L. y PIORNO, A. (1998). *Análisis del comportamiento temporal de la temperatura en Castilla y León: Primeros resultados*. En *El Clima y Medio Ambiente urbano en ciudades ibéricas e iberoamericanas.*, 577-591, Ed. Parteluz.
- [9] LABAJO, J.L. y PIORNO, A. (1999). *Comportamiento de variables climáticas en Castilla y León: Temperatura Mínima Media Anual*. En *La Climatología española en los albores del siglo XXI*. Publicaciones de la AEC. Serie A, nº 1, 259-266.
- [10] LENDASSE A., VERLEYSEN M., DE BODT E., COTTRELL M. and GRÉGOIRE P. (1998). Forecasting Time-Series by Kohonen Classification.. European Symposium on Artificial Neural Networks, Bruges (Belgium), D-Facto Publications (Brussels).
- [11] LEVENE, H. (1960). *Contributions to probability and Statistics: Assays in Honour of Harold Hotelling*. I. Olkin et al. (Eds.) Stanford Univesity Press, Stanford, California.

- [12] NELSON M, HILL T, REMUS W and O'CONNOR M. (1999). Time Series Forecasting Using Neural Networks: Should the Data be Deseasonalized First? *Journal of Forecasting*, **18**: 359-367.
- [13] QI M. and ZHANG G. P. (2001). An investigation model selection criteria for neural network time series forecasting. *European Journal of Operational Research*, **132**: 666-680.
- [14] SAHAMBI, H.S.; KHORASANI, K. (2003). A neural-network appearance-based 3-D object recognition using independent component analysis. *Neural Networks, IEEE Transactions*, **14**: 138-149.
- [15] SANTOS-ANDRÉ, T. C. S. y DA SILVA, A. C. R. (1999). A neural network made of a Kohonen's SOM coupled to a MLP trained via backpropagation for the diagnosis of malignant breast cancer from digital mammograms. *Neural Networks, IJCNN. International Conference*, **5**: 3647- 3650.
- [16] SCHÖNWISE, C.D.; RAPP, J.; FUNCHS, T. and DENHARD, M. (1994). Observed climate trends in Europe 1891-1990. *Meteorol. Zeitschrift*, **3**: 22-28.
- [17] TANG B., HSIEH W. W., MONAHAN A. H. and TANGANG F. (2000). T. Skill Comparisons between Neural Networks and Canonical Correlation Analysis in Predicting the Equatorial Pacific Sea Surface Temperatures. *Journal of Climate*, **13**. 287-293
- [18] VÁZQUEZ E., CHACÓN O. L. y ALTUVE H. J. (1999). Aplicación del análisis de componente principal y redes neuronales en la identificación de osciladores de potencia. *Ingenierías*, **2** (5):3-12.
- [19] WEDDING II D. K. and CIOS K. J. (1996). Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model. *Neurocomputing* **10**, 149-168.
- [20] ZHANG, G. P. (2003). Time Series Forecasting using a hybrid ARIMA and Neural Network Model. *Neurocomputing*, **50**: 159-175.
- [21] ZHANG G. P. y QI M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, **160**. 501-514

ANEXO

Tabla 1. Configuración de los patrones de entrenamiento y prueba según el esquema de predicción en un paso de tiempo. (N= n° de datos por patrón, NTr= n° de patrones de entrenamiento, NTe= n° de patrones de prueba)

Patrón	Entrada	Salida deseada
Entrenamiento 1	t(1), t(2),..., t(N)	t(N+1)
Entrenamiento 2	t(2), t(3),..., t(N+1)	t(N+2)
⋮	⋮	⋮
Entrenamiento NTr	t(NTr), t(NTr+1),..., t(NTr+N-1)	t(NTr+N)
Prueba 1	t(NTr+1), t(NTr+2),..., t(NTr+N)	t(NTr+N+1)
Prueba 2	t(NTr+2), t(NTr+3),..., t(NTr+N+1)	t(NTr+N+2)
⋮	⋮	⋮
Prueba NTe	t(NTr+NTe), t(NTr+NTe+1),..., t(NTr+NTe+N-1)	t(NTr+NTe+N)

Tabla 2. Configuración inicial del modelo (N, L y M son el n° de neuronas de capa de entrada a capa de salida).

Tipo RNA	MLP
N	N° de datos de cada patrón
L	N/2
M	1
Algoritmo de aprendizaje	Retropropagación con momento
Tasa de entrenamiento (η)	0,05
Momento (μ)	0,9
F Activación 1	Tangente hiperbólica
F Activación 2	Tangente Hiperbólica
F Activación 3	Rampa

Tabla 3. Valores del coeficiente de determinación y del MSE, en el entrenamiento y la prueba, para el conjunto de experimentos P.

Ref.	N	NTr	NTe	Entrenamiento		Prueba	
				R ²	MSE	R ²	MSE
P1	180	432	60	0,880	3,42	0,844	4,38
P2	144	468	60	0,592	11,56	0,645	9,80
P3	120	492	60	0,931	1,96	0,899	2,87
P4	96	516	60	0,919	2,31	0,884	3,26
P5	60	552	60	0,304	19,70	0,328	18,41

Tabla 4. Valores del coeficiente de determinación y del MSE, en el entrenamiento y la prueba, para los experimentos A.

Ref.	Algoritmo	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
A1	Retropropagación sin momento	0,931	1,96	0,901	2,81
A2	Retropropagación con momento	0,931	1,96	0,899	2,87
A3	Tasa de aprendizaje variable sin momento	1,000	0,00	0,865	3,87
A4	Tasa de aprendizaje variable con momento	1,000	0,00	0,847	4,48
A5	Retropropagación elástico	0,996	0,11	0,831	4,99

Tabla 5. Valores del coeficiente de determinación y del MSE, en el entrenamiento y la prueba, para el conjunto de experimentos A.

Ref.	Algoritmo	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
A6	Retropropagación sin momento	0,931	1,96	0,901	2,81
A7	Retropropagación con momento	0,931	1,96	0,899	2,87
A8	Tasa de aprendizaje variable sin momento	0,948	1,49	0,911	2,53
A9	Tasa de aprendizaje variable con momento	0,947	1,49	0,910	2,57
A10	Retropropagación elástico	0,947	1,49	0,905	2,77

Tabla 6. Valores del coeficiente de determinación y de MSE, en el entrenamiento y la prueba, según el MSE fin de entrenamiento.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
M1	1,70	0,942	1,66	0,911	2,52
M2	1,60	0,944	1,60	0,912	2,48
M3	1,50	0,948	1,49	0,911	2,53
M4	1,40	0,952	1,39	0,910	2,64

Tabla 7. Valores del coeficiente de determinación y de MSE, en el entrenamiento y la prueba, según el MSE fin de entrenamiento.

Experimento	Neuronas de la capa oculta	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
N1	50	0,944	1,60	0,904	2,71
N2	55	0,946	1,55	0,903	2,84
N3	60	0,944	1,59	0,912	2,48
N4	65	0,944	1,59	0,907	2,64
N5	70	0,944	1,60	0,890	3,22

Tabla 8. Valores del coeficiente de determinación y de MSE, en el entrenamiento y la prueba, según el MSE fin de entrenamiento.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
D1	0,1	0,997	0,10	0,861	4,27
D2	1	0,965	1,00	0,885	3,47
D3	1,5	0,948	1,48	0,899	3,01
D4	2	0,931	2,00	0,908	2,68
D5	2,5	0,920	2,44	0,910	3,04

Tabla 9. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos Ds.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
Ds1	0,001	1,000	0,00	0,879	3,72
Ds2	0,01	1,000	0,00	0,880	3,67
Ds3	0,1	0,997	0,10	0,884	3,49
Ds4	0,5	0,983	0,49	0,884	3,45
Ds5	1	0,967	0,98	0,881	3,90
Ds6	1,5	0,949	1,47	0,876	3,99
Ds7	2	0,935	1,88	0,876	4,03
Ds8	2,5	0,934	2,05	0,876	3,45

Tabla 10. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos DsD.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
DsD1	0,001	1,000	0,00	0,857	4,39
DsD2	0,01	1,000	0,01	0,858	4,35
DsD3	0,1	0,997	0,10	0,862	4,20
DsD4	0,5	0,983	0,50	0,868	3,96
DsD5	1	0,967	0,96	0,872	3,89
DsD6	1,5	0,951	1,45	0,873	3,98
DsD7	2	0,936	1,91	0,874	3,93
DsD8	2,5	0,922	2,36	0,873	4,00

Tabla 11. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos AP.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
AP1	0,5	0,982	0,50	0,900	2,96
AP2	1	0,965	0,99	0,913	2,64
AP3	1,2	0,958	1,19	0,915	2,63
AP4	1,4	0,951	1,39	0,915	2,66
AP5	1,6	0,944	1,59	0,912	2,77

Tabla 12. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos NR.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
NR1	0,01	0,492	24,354	0,374	39,453
NR2	0,001	0,927	2,130	0,623	11,936
NR3	0,0005	0,966	1,437	0,619	11,642
NR4	0,0001	0,988	0,343	0,693	9,859

Tabla 13. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos AM.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
AM1	1	0,965	0,097	0,895	4,27
AM2	1,2	0,962	1,138	0,897	2,874
AM3	1,4	0,951	1,382	0,903	2,747
AM4	1,6	0,948	1,543	0,905	2,939

Tabla 14. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para el conjunto de experimentos ST.

Ref.	MSE fin de entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
ST1	0,1	0,993	0,21	0,880	3,45
ST2	0,5	0,963	1,07	0,884	3,29
ST3	1	0,910	2,17	0,868	3,72
ST4	1,5	0,893	3,14	0,842	4,64

Tabla 15. Coeficiente de determinación y MSE en las fases de entrenamiento y prueba, para los mejores experimentos.

Ref.	MSE fin entrenamiento	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
D4	2	0,931	2,000	0,908	2,680
Ds8	2,5	0,934	2,045	0,876	3,445
DsD7	2	0,936	1,913	0,874	3,933
AP3	1,2	0,958	1,190	0,915	2,630
NR4	0,0001	0,988	0,343	0,693	9,859
AM3	1,4	0,951	1,382	0,903	2,747
ST2	0,5	0,963	1,069	0,884	3,293

Tabla 16. Coeficientes de determinación y MSE, en las fases de entrenamiento y prueba, obtenidos en la aplicación del modelo local a las series de TminMed observadas en estaciones de Castilla y León.

Experimento	Estaciones	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
mLAv	Ávila	0,930	1,98	0,869	4,03
mLBu	Burgos	0,903	2,00	0,819	3,83
mLLe	León	0,911	1,98	0,846	3,60
mLSa	Salamanca	0,923	2,04	0,859	3,99
mLSo	Soria	0,924	2,03	0,770	6,77
mLVa	Valladolid	0,923	2,03	0,861	3,75
mLVn	Villanubla	0,917	2,00	0,855	3,43
mLZa	Zamora	0,924	1,97	0,864	3,74

Tabla 17. Coeficientes de determinación y MSE, en las fases de entrenamiento y prueba, obtenidos en la aplicación del modelo local a las series de TminMed observadas en estaciones de Castilla la Mancha.

Ref.	Estaciones	Entrenamiento		Prueba	
		R ²	MSE	R ²	MSE
mLLla	Los Llanos	0,944	2,00	0,922	3,05
mLCR	Ciudad Real	0,947	1,94	0,914	3,61
mLCu	Cuenca	0,937	2,00	0,915	3,07
mLGu	Guadalajara	0,934	1,99	0,871	4,06
mLTo	Toledo	0,946	1,99	0,920	3,23