

UNA RED NEURONAL COMO HERRAMIENTA DE PREDICCIÓN DE VARIABLES CLIMÁTICAS: APLICACIÓN A LA TEMPERATURA MÍNIMA MEDIA MENSUAL EN CASTILLA y LEÓN.

Angel L. Labajo⁽¹⁾ y José L. Labajo⁽²⁾

⁽¹⁾Dpto. de Informática y Automática. Universidad de Salamanca. e-mail: alabajo@usal.es

⁽²⁾Dpto.de Física General y de la Atmósfera. Universidad de Salamanca. e-mail: jll45@usal.es

RESUMEN

Una Red Neuronal Artificial (RNA) del tipo perceptron multicapa (Multilayer Perceptron; MLP) se emplea como base de un modelo local y otro regional para el pronóstico de la variable climática Temperatura mínima media mensual (TminMed). Ambos modelos son alimentados por las series de temperatura mínima media mensual (TminMed) obtenidas en estaciones meteorológicas de la red sinóptica y climatológica de la Agencia Estatal de Meteorología (AEMET) en Castilla y León.

La mayor parte de los datos se emplean para entrenar la RNA de tipo MLP y el resto para validar el modelo.

Los resultados obtenidos proporcionan un alto grado de ajuste entre las series reales y las simuladas, tanto en el modelo local como en el modelo regional, lo que confirma la utilidad de esta herramienta en la predicción del comportamiento temporal de variables climáticas. Además el modelo regional mejora ligeramente los resultados obtenidos con el modelo local.

INTRODUCCIÓN

Las Redes Neuronales Artificiales (RNAs) fueron concebidas originalmente como un intento de modelar, entender y explicar cómo funciona la biofisiología del cerebro humano. Se pueden considerar como un modelo artificial de tratamiento de información inspirado en el sistema nervioso biológico, que se implementa en un ordenador mediante algoritmos informáticos. Estos algoritmos simulan, de forma artificial, elementos simples o neuronas artificiales.

Las RNAs se pueden aplicar para la resolución de problemas muy diversos como pilotos automáticos, análisis de mercado de capitales, reconocimiento de individuos a partir de información facial, sistemas de visión artificial, etc. (Demuth y Beale, 2000).

En los últimos años las RNAs se están aplicando a los campos de Meteorología y Climatología con resultados satisfactorios (Cannon y McKendry, 2002).

Comrie (1997) empleó una RNA para predecir concentraciones de ozono en áreas metropolitanas, Mihalakakou *et al.* (1998) para predecir series de temperatura, Bertil y Mohsen (2007) para la predicción de la temperatura en interiores de edificios, entre otros. Igualmente Lu y Viljanen (2009) emplearon una RNA para la predicción de la temperatura y la humedad relativa en interiores. Juhos *et al.* (2009) emplearon una RNA para la predicción de series de datos de concentración de NO y NO₂.

La mayor ventaja de las RNAs es su capacidad para realizar modelizaciones no lineales, de forma que pueden ser consideradas como aproximadores universales (Curry y Morgan, 2006).

Sin embargo los modelos RNAs también presentan varios inconvenientes ya que los parámetros de la RNA deben ser determinados por el usuario, u optimizados experimentalmente. Además requieren de una fase previa de entrenamiento de la RNA consistente en algoritmos de entrenamiento que requieren la inicialización de algunos parámetros que son definidos por el usuario, ya que no pueden ser deducidos directamente de los datos de entrenamiento.

Se ha sugerido que las RNAs pueden ser una alternativa a los métodos estadísticos tradicionales en el campo de la predicción de series temporales (Zhang y Qi, 2005) y durante los últimos años se han comenzado a usar para desarrollar modelos de predicción de series temporales, en particular climáticas (Qi, y Zhang, 2001; Cannon y McKendry, 2002).

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. (Nelson *et al.*, 1999).

DATOS




Fig. 1.- Observatorios de Castilla y León.

Las series de la variable TminMed se han obtenido a partir de medidas diarias de la variable temperatura mínima, obtenidas en estaciones meteorológicas de la red sinóptica y climatológica de la Agencia Estatal de Meteorología (AEMET) en Castilla y León. Los observatorios considerados se muestran en la figura 1.

El intervalo de tiempo de estudio se extiende desde enero de 1945 hasta diciembre de 2004

REDES NEURONALES ARTIFICIALES (RNAs)

Una neurona artificial es una unidad simple de procesamiento de datos. En la figura 2 se muestra su estructura y la forma de transmisión de los datos de entrada a través de ella.




Fig. 2.- Neurona artificial.

Donde:

$\vec{x} = (x_1, x_2, \dots, x_N)$ Vector de datos de entrada a la neurona.

$\vec{w} = (w_1, w_2, \dots, w_N)$ Vector de pesos asociados a las conexiones de entrada a la neurona.

u : Función de red.

f : Función de activación.

b : Umbral de activación de la neurona.

n : Entrada efectiva a la neurona.

a : Salida de la neurona.

Utilizando una función de red de base lineal la salida queda como se muestra.

$$n = u(\vec{w}, \vec{x}) = \sum_{i=1}^N w_i x_i + b$$

$$a = f(n) = f\left(\sum_{i=1}^N X_i W_i + b\right)$$

Entre las funciones de activación principales se destacan las tipo escalón, lineal y sigmoideal. Sin embargo estas funciones de activación simulan de forma bastante tosca la actividad de las neuronas reales. En la bibliografía más reciente se pueden encontrar algunos tipos más como las tangentes hiperbólicas, gaussianas, lineal a tramos y las de tipo coseno. En la figura 3 se muestran las gráficas de algunas de ellas.

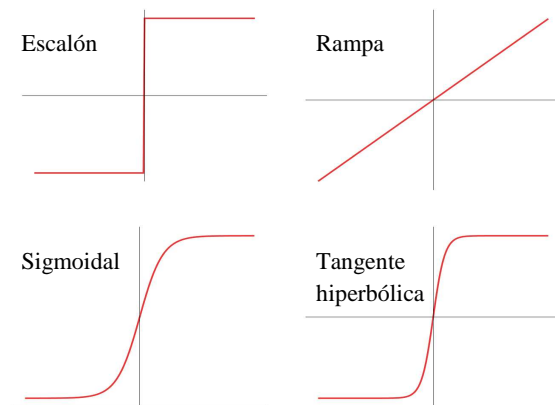


Fig. 3.- Funciones de activación tipo escalón, rampa, sigmoideal y tangente hiperbólica

Las neuronas están ligadas entre sí mediante conexiones ponderadas, de forma que la salida de una neurona, multiplicada por un peso, constituye la entrada a otras neuronas.

En gran parte de las RNAs las neuronas están organizadas en capas, de forma que todas las neuronas de una misma capa tienen la misma función de activación. Además es frecuente que las salidas de las neuronas de una capa se conecten con todas las neuronas de la capa siguiente. En algunos casos neuronas correspondientes a una misma capa se conectan entre sí mediante conexiones denominadas de competición. En la figura 4 cada neurona se ha representado con un círculo.




Fig. 4.- Capa de m neuronas.

Una RNA está formada por varias capas de neuronas conectadas entre sí. La primera capa es alimentada por los datos de trabajo y se la denomina capa de entrada. La última capa es la capa de salida. Entre ambas capas se sitúa una o más capas ocultas.

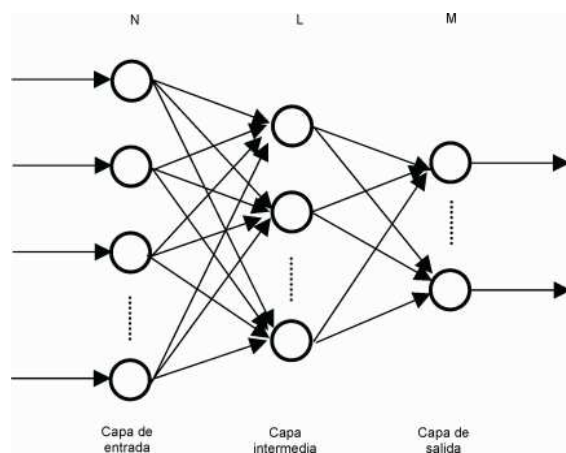


Fig. 5.- RNA MLP con una capa intermedia.

En la figura 5 se muestra una RNA de tipo perceptron multicapa (Multilayer Perceptron; MLP) con una única capa oculta, N neuronas en la capa de entrada, L en la intermedia y M en la de salida. Cada neurona de una capa está conectada con todas las neuronas de la capa posterior.

ENTRENAMIENTO Y PRUEBA DE UNA RNA

El uso de una RNA conlleva una fase de entrenamiento, en la que se ajustan unos pesos asociados a cada conexión entre neuronas, que genera el modelo de comportamiento de la variable según la red. El modelo se valida en la fase de prueba. Parte de las series de datos se emplean en el entrenamiento y el resto en la prueba. Los datos se agrupan en patrones de entrenamiento y prueba. Los criterios para la obtención de estos patrones dependerán de cada problema en concreto y responden a la necesidad de presentar los datos a la RNA en el formato más adecuado para el aprendizaje de la misma.

Isasi y Galván (2004) proponen una configuración, en la que los patrones aparecen desfasados en un instante, para realizar predicciones en un paso de tiempo. En la tabla 1 se muestra esta configuración, siendo $t(x)$ los datos de entrada o salida, N el número de datos por patrón, N_{Tr} el número de patrones de entrenamiento y N_{Te} el número de patrones de prueba, E_1 a $E_{N_{Tr}}$ los patrones de entrenamiento y P_1 a $P_{N_{Te}}$ los patrones de prueba.

Tabla 1.- Configuración de los patrones de entrenamiento y prueba según el esquema de predicción en un paso de tiempo.

Patrón	Entrada	Salida
E_1	$t(1), t(2), \dots, t(N)$	$t(N+1)$
E_2	$t(2), t(3), \dots, t(N+1)$	$t(N+2)$
\vdots	\vdots	\vdots
$E_{N_{Tr}}$	$t(N_{Tr}), t(N_{Tr}+1), \dots, t(N_{Tr}+N-1)$	$t(N_{Tr}+N)$
P_1	$t(N_{Tr}+1), t(N_{Tr}+2), \dots, t(N_{Tr}+N)$	$t(N_{Tr}+N+1)$
P_2	$t(N_{Tr}+2), t(N_{Tr}+3), \dots, t(N_{Tr}+N+1)$	$t(N_{Tr}+N+2)$
\vdots	\vdots	\vdots
$P_{N_{Te}}$	$t(N_{Tr}+N_{Te}), t(N_{Tr}+N_{Te}+1), \dots, t(N_{Tr}+N_{Te}+N-1)$	$t(N_{Tr}+N_{Te}+N)$

ALGORITMO DE RETROPROPAGACIÓN

Los algoritmos de entrenamiento son algoritmos informáticos que permiten el cálculo de los pesos asociados a cada conexión de la RNA. 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. Los valores de los pesos se ajustan de una forma iterativa hasta que se alcanza una condición de fin de entrenamiento, que puede ser un número máximo de iteraciones o un valor mínimo del error cuadrático medio (Mean Square Root; MSE) entre las series reales y las simuladas en esta fase.

Variantes del algoritmo BP pueden mejorar su rendimiento. Entre ellas se puede destacar el BP con tasa de entrenamiento variable, BP elástico o quickprop.

MODELO RNA

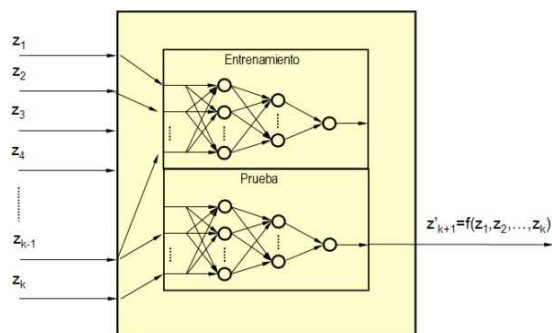


Fig. 5.- Modelo RNA de predicción de series temporales.

En la figura 5 se presenta un esquema del modelo de RNA en el que se observa como realiza una predicción en un paso de tiempo hacia adelante, a partir de los valores anteriores de la serie.

$$z'_{k+1} = f(z_1, z_2, \dots, z_k)$$

Los datos de entrada al modelo fueron tratados mediante transformaciones, previas a la aplicación del modelo, de las series de trabajo. Según Nelson *et al.* (1999) los modelos RNAs, presentan resultados mejores al ser alimentados con las series desestacionalizadas. Según Zhang y Qi (2005) 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.

En la figura 6 se muestra un esquema más detallado del modelo. En la etapa de entrenamiento se proporciona a la RNA la matriz (**P**) de patrones de entrenamiento y el vector de objetivos **T**. Finalizado el entrenamiento, según el algoritmo correspondiente, la RNA proporciona un vector de salidas **a'** y la matriz (**W**) de pesos asociados a las conexiones. Los patrones de entrenamiento y prueba, (**P**) y (**Pt**), son sometidos a una etapa de tratamiento previo, de tal forma que las entradas efectivas al modelo son (**P'**) y (**Pt'**), en las etapas de entrenamiento y prueba respectivamente. Las salidas proporcionadas por el modelo, **a'** (entrenamiento) y **at'** (prueba), se corresponden con los datos tratados. Es necesario realizar una transformación inversa de los datos para poder validar el modelo.

Después de invertir la transformación, la validación se realiza con los vectores **a** y **T** (entrenamiento) y **at** y **Tt** (prueba).

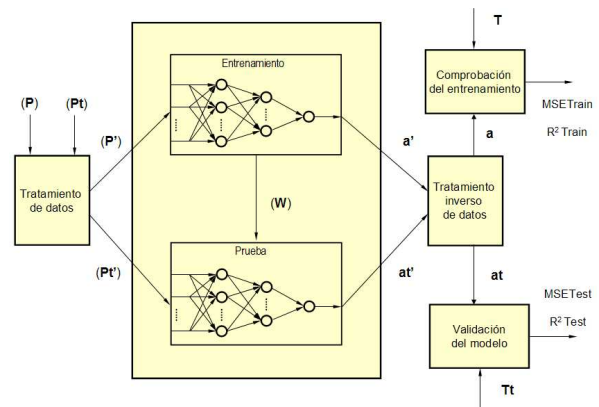


Fig. 6.- Patrones de entrenamiento y prueba con tratamiento previo de los datos, salidas del modelo, tratamiento inverso y validación del modelo.

MODELO LOCAL Y REGIONAL

Ambos modelos, obtenidos según se ha indicado, proporcionan una estimación en un paso posterior de tiempo de la serie de trabajo (paso de tiempo: un mes). La diferencia entre el modelo local y el regional se encuentra en las series de datos empleadas para entrenar la RNA MLP. En el modelo local la RNA se entrena solamente con la serie de datos que se pretende estimar. Sin embargo en el modelo regional se emplean todas las series de datos obtenidas en los observatorios de Castilla y León.

METODOLOGÍA

Este trabajo se desarrolló en dos etapas.

1. Ajuste de los parámetros de los modelos local y regional.
2. Aplicación de los modelos local y regional a las series de trabajo.

El ajuste del modelo se realizó mediante una metodología experimental por ser la más común en la bibliografía consultada. Según Cottrell *et al.* (1995) la mayoría de las metodologías para configurar los modelos RNAs son experimentales y es difícil encontrar una metodología general en los trabajos publicados. Para Qi y Zhang (2001) no existe una metodología sistemática para la construcción de un modelo RNA.

En esta primera fase experimental de la metodología se determinaron aspectos como:

1. Tipo de RNA MLP: número de capas y neuronas en cada una de ellas, funciones de activación de cada una de las capas.
2. Patrones de entrenamiento y prueba (según la configuración mostrada en la tabla 1): longitud de los patrones (número de datos por patrón) y número de patrones de entrenamiento y prueba.
3. Tratamiento de los datos de entrada a la RNA.
4. Algoritmo de aprendizaje y condición de fin de entrenamiento.

Al aplicar el modelo local y el regional se obtienen las series simuladas por ambos modelos. La validación de los mismos se realiza comparando las series simuladas por los modelos y las series reales. Para ello se utilizan las gráficas de secuencia, de dispersión y los índices MSE (Mean Square Root) y el coeficiente de determinación (R^2) entre series reales y simuladas.

RESULTADOS

La etapa de ajuste experimental permitió determinar la RNA de tipo MLP (tabla 2).

Tabla 2.- Resultados del ajuste experimental.

Nº de capas	3
Nº de neuronas por capa	120/ 60/ 1
Funciones de activación por capas	Tan. Hiperbólica/ Tan. Hiperbólica/ Rampa
Tratamiento previo de los datos	Diferenciación
Algoritmo de entrenamiento	BP con tasa de entrenamiento variable
Condición de fin de entrenamiento	20.000 iteraciones
	MSE < 2

En las figuras 7 a 14 aparecen las gráficas de secuencia correspondientes a los modelos local y regional. En ambos modelos es de destacar un alto grado de concordancia entre las series de valores reales y previstos por el modelo con las mismas características generales de evolución y tendencia entre las series de valores reales y las series de valores obtenidos por el modelo. El modelo no es capaz de ajustar totalmente las anomalías que aparecen en las series reales, como se puede observar, entre otros, en los intervalos comprendidos entre los meses finales de 2000 y los iniciales de 2001 y finales de 2001 y de inicio de 2002.

En la tabla 3 se muestran los valores de los índices MSE y R^2 calculados entre las series reales y las simuladas en las fases de entrenamiento y prueba con el modelo local. En todos los casos los valores de los índices indican un alto grado de ajuste entre series reales y simuladas. Estos resultados, como es lógico, son mejores en la fase de entrenamiento. Es de destacar el caso de Soria en el que, aun presentando un ajuste bueno, se obtienen un resultado peor que en las otras estaciones. En la figura 10, correspondiente a Soria, podemos observar como la serie real presenta una aparente anomalía en el dato correspondiente a septiembre de 2001. La serie simulada demuestra que el modelo presenta también este comportamiento pero atenuado y con un desfase de un mes.

En la tabla 4 se muestran los valores de los índices MSE y R^2 calculados entre las series reales y las simuladas con el modelo local y con el regional. En todos los casos se observa una ligera mejoría en los resultados del modelo regional frente a los del local en la etapa de validación del modelo.




Fig. 7.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de ÁVILA).




Fig. 9.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de LEÓN).




Fig. 8.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de BURGOS).

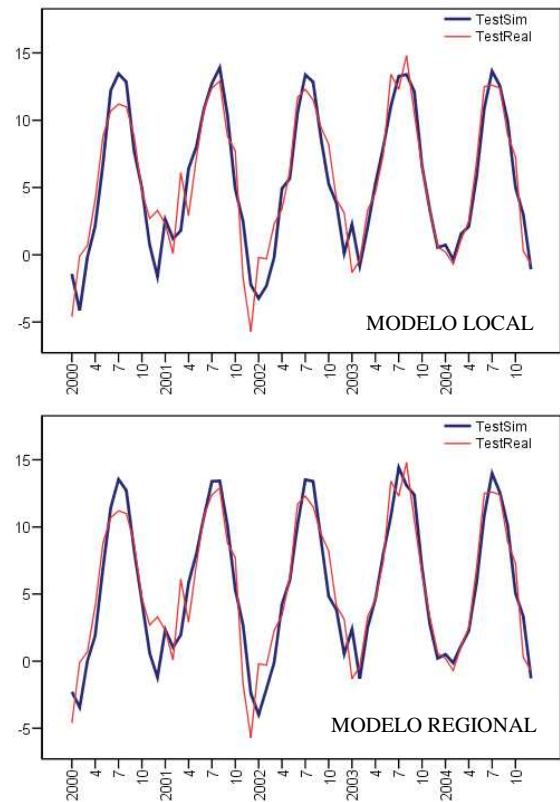


Fig. 10.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de SALAMANCA).

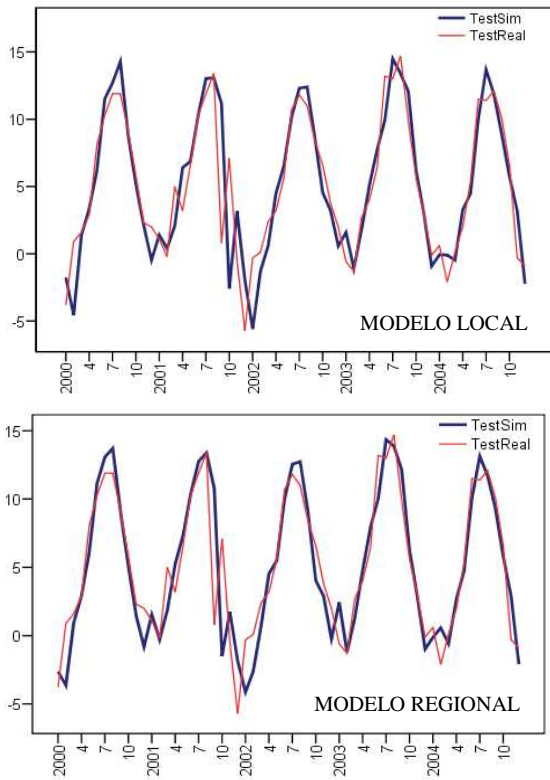


Fig. 11.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de SORIA).

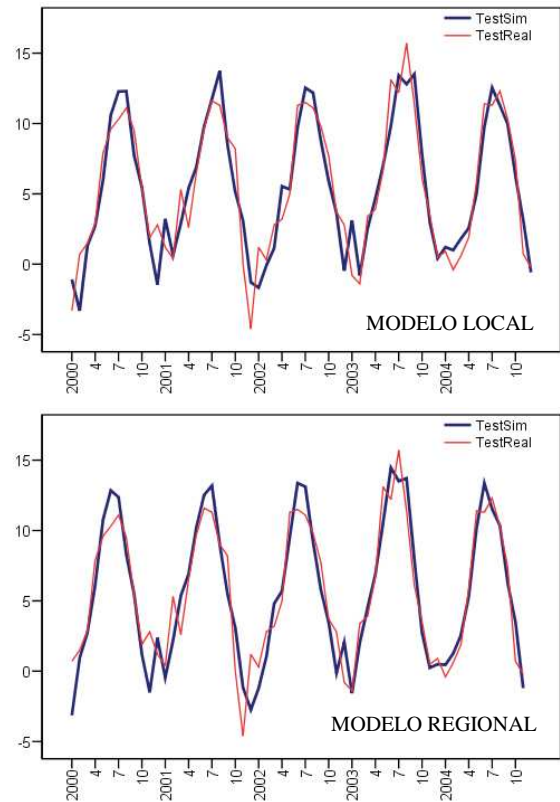


Fig. 13.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de VILLANUBLA).




Fig. 12.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de VALLADOLID).

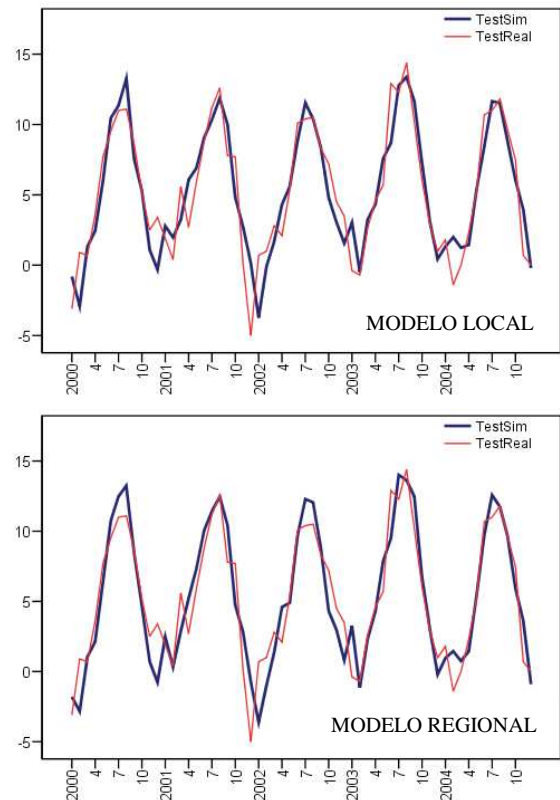


Fig. 14.- Secuencia de las series reales y las simuladas con los modelos local y regional (serie de observaciones de ZAMORA).

Tabla 3.- Coeficientes de determinación y MSE correspondientes a las series reales y simuladas con el modelo local. (Etapas de entrenamiento y prueba).

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

Tabla 4.- Coeficientes de determinación y MSE correspondientes a las series reales y simuladas con el modelo local y el modelo regional.

	Modelo local		Modelo regional	
	R ²	MSE	R ²	MSE
Ávila	0,869	4,03	0,879	3,98
Burgos	0,819	3,83	0,840	3,82
León	0,846	3,60	0,862	3,55
Salamanca	0,859	3,99	0,866	3,85
Soria	0,770	6,77	0,799	5,89
Valladolid	0,861	3,75	0,878	3,52
Villanubla	0,855	3,43	0,865	3,39
Zamora	0,864	3,74	0,874	3,72

CONCLUSIONES

Los resultados obtenidos demuestran que los modelos generados por la RNA pueden considerarse como útiles para el pronóstico de la

temperatura media mensual para un paso de tiempo, es decir para el mes siguiente.

La realización de un tratamiento previo de los datos diferenciando, desestacionalizando o diferenciando y desestacionalizando, la serie mejora los resultados proporcionados por el modelo. El tratamiento de datos que proporciona mejores resultados es el correspondiente a la diferenciación de la serie.

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. Además el modelo RNA es capaz de ajustar las variaciones en los valores extremos que presentan las series de datos observadas. Con el modelo regional se mejoran ligeramente los resultados obtenidos con el modelo local.

BIBLIOGRAFÍA

BERTIL T. and MOHSEN S. (2007). Artificial neural network models for indoor temperature prediction: investigations in two buildings. *Neural Computing and Applications*, **16**: 81-89.

CANNON A. J and 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.

COMRIE, A. C. (1997). Comparing Neural Networks and Regresión Models for Ozone Forecasting. *Journal of the Air & Waste Management Association*, **47**: 653-663.

COTTRELL, M, GIRARD B., GIRARD YVONNE, MANGEAS M. AND MULLER C. (1995) Neural Modelling for Time Series: A Statistical Stepwise Method for Weight Elimination. *IEEE transactions on neural networks*, **6**: 1355-1363.

CURRY B. and MORGAN P.H. (2006) Model selection in Neural Networks: Some difficulties. *European Journal of Operational Research*, **170**: 567- 577.

DEMUTH H y BEALE M. (2000). *Neural Network Toolbox. User's Guide. (Version 4)*. http://www.mathworks.com/access/helpdesk/help/p_df_doc/nnet/nnet.pdf.

ISASI VIÑUELA P. y GALVÁN LEÓN I. M. (2004). *Redes de neuronas artificiales. Un enfoque práctico*. Pearson Educación.

JUHOS I., MAKRA L. and TÓTH B. The behaviour of the multi-layer perceptron and the support vector regression learning methods in the prediction of NO and NO₂ concentrations in Szeged, Hungary. (2009). *Neural Computing and Applications*, **18**: 193- 205.

LU T. and VILJANEN M. Prediction of indoor temperature and relative humidity using neural networks models: model comparison. (2009). *Neural Computing and Application*, **18**: 345-357.

MIHALAKAKOU G., SANTAMOURIS M. AND ASIMAKOPOULOS D. Modeling Ambient Air Temperature Time Series Using Neural Networks. . (1998) *Journal of Geophysical Research*. **103**: 19,509-19,517.

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.

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.

ZHANG G. P. and QI M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, **160**: 501-514