

A. Martínez-Romero, J.F. Ortega, J.A. de Juan, J.M. Tarjuelo y M.A. Moreno

**MODELOS DE ESTIMACIÓN DE RADIACIÓN SOLAR GLOBAL CON LIMITACIÓN
DE DATOS Y SU DISTRIBUCIÓN ESPACIAL EN CASTILLA-LA MANCHA**

Separata ITEA

INFORMACIÓN TÉCNICA ECONÓMICA AGRARIA, VOL. **108** N.º 4 (426-449), 2012

Modelos de estimación de radiación solar global con limitación de datos y su distribución espacial en Castilla-La Mancha

A. Martínez-Romero¹, J.F. Ortega, J.A. de Juan, J.M. Tarjuelo y M.A. Moreno

Centro Regional de Estudios del agua, Universidad de Castilla-La Mancha, 02071 Albacete, España

Resumen

La estimación de la radiación solar global (R_{sg}) constituye un procedimiento necesario cuando se carece de suficientes registros observados en una región, a la hora de estudiar la distribución espacial y temporal de parámetros energéticos con distintos fines. Si bien es la fuente primaria de energía del sistema climático, la medición de la radiación solar sólo se efectúa en un número limitado de estaciones meteorológicas.

El objetivo de este trabajo es evaluar modelos, con diferente grado de complejidad, que permitan estimar la R_{sg} en la región de Castilla-La Mancha (CL-M) con alta bondad en el ajuste de los resultados, a partir de datos básicos ofrecidos por estaciones termoplumiométricas y representar gráficamente la distribución espacial y temporal de este parámetro en la región.

En C-LM se dispone de series de datos medios mensuales procedentes de estaciones termoplumiométricas, por lo que resulta interesante conocer la bondad de las estimaciones de R_{sg} con distintos métodos en situaciones de limitación de registros. Las metodologías analizadas se basan en la aplicación de técnicas de regresión lineal (RL), redes neuronales artificiales (RNAs) y la metodología propuesta por FAO basada en la ecuación de Hargreaves, contrastando los resultados con los valores medidos en estaciones completas. Los modelos que mejor reproducen los valores observados son los basados en RNAs con datos de temperaturas máximas, mínimas y valores de radiación solar global extraterrestre, y el modelo de Hargreaves, con errores relativos de validación que oscilan entre el 5,8% y 8,3%, y, entre el 7,1% y 9,7% respectivamente.

Utilizando la serie de datos de R_{sg} histórica representativa elaborada mediante la aplicación de RNAs a partir de datos registrados en estaciones termoplumiométricas, se ha plasmado gráficamente la caracterización de la R_{sg} en C-LM.

Palabras clave: Radiación solar global; limitación de datos; Redes neuronales artificiales; Interpolación de la radiación solar global.

Abstract

Estimating models of global solar radiation with limiting data and its spatial distribution in Castilla-La Mancha

Estimating global solar radiation (R_{sg}) is required under missing data conditions. It is an important factor to study the spatial and temporal distribution of energy parameters for different purposes. Despite being the primary energy source of the climate system, solar radiation is measured only at a limited number of weather stations.

1. Autor para correspondencia: Angel.mromero@uclm.es

The main objective of this paper is to evaluate different models to estimate the R_{sg} in the region of Castilla-La Mancha (CL-M) from data obtained from termopluiometric weathers station. In addition, spatial and temporal R_{sg} will be mapped.

In C-LM, historical monthly average data from temperature and rainfall series are available. For estimation of R_{sg} values, several approaches were applied: 1) lineal regression (RL); 2) artificial neural networks (RNA), and 3) the Hargreaves model. The goodness-of-fit of each model was computed for each model. The best models were those based on ANNs using maximum and minimum temperature values and extraterrestrial radiation (R_a) data. The Hargreaves model showed also a proper behaviour. The relative errors found for model validation ranged between 5.8% and 8.3% for ANN models and between 7.1% and 9.7% for the Hargreaves model.

By using R_{sg} historical data which are developed through the application of RNAs from termopluiometric data, the R_{sg} that characterizes C-LM has been mapping.

Key words: Solar global radiation, Limited data; Artificial neural networks; Interpolation of the global solar radiation.

Introducción

La energía solar es, además de fuente de energía para el desarrollo de la vida, un recurso natural. El conocimiento de su disponibilidad, su distribución geográfica y comportamiento a lo largo del año, permiten su mejor aprovechamiento y tiene una enorme importancia en términos ecológicos y económicos (Pons, 1996).

El aprovechamiento de la energía solar está condicionado a la intensidad de radiación solar incidente. La estimación de la radiación solar global (R_{sg}) es necesaria cuando se carece de los registros observados y generalizados en todo el territorio de una región, y se pretende estudiar la distribución espacial y temporal de parámetros energéticos con distintos fines. Adquiere gran importancia en la planificación de actividades como la agricultura, el turismo, la planificación urbana, y la posible utilización directa de la energía solar como fuente de energía renovable (de la Casa et al., 2003).

Actualmente es común la elaboración de mapas de Radiación Solar (R_s), donde normalmente se representan los valores promedios diarios, mensuales o anuales, a partir de me-

diciones vía satélite (Hurtado and Sobrino, 2001; Sidrach et al. 2002; Cristóbal et al., 2009). También se utilizan los datos obtenidos mediante observatorios sobre el terreno, generalmente ubicados en las ciudades y grandes centros poblados (Font, 2000; DMAGA, 2008).

La medición de la R_s se efectúa en un número limitado de estaciones meteorológicas (Rietveld, 1977; Goodin et al., 1999) y, ha sido uno de los elementos menos evaluados del clima. Con frecuencia, en el ámbito agrario, la fiabilidad de los registros climáticos disponibles es baja, especialmente, los referidos a la R_s (observación directa de Radiación solar global (R_{sg}) o número de horas de insolación).

Existen diversos modelos empíricos para la generación de datos de R_{sg} en ausencia de medidas directas (Allen et al., 1998; Allison, 2001; Castellví y Elías, 2001; Pelayo, 2004). Allen et al. (1998) exponen procedimientos sencillos, a partir del número de horas de insolación diaria (Kasten et al., 1996). Los modelos propuestos se basan en la interpolación de datos conocidos, modelos de regresión lineal, o los que se sustentan en la amplitud térmica (Hargreaves and Samani, 1985; Hargreaves, 1994). Algunos autores han estudiado relaciones empíricas entre las horas

de luz solar y la R_{sg} (Glover and McCulloch, 1958; Rees, 1968) no ofreciendo mejores resultados que los recomendados por Allen et al. (1998). Pons (1996) propone la estimación de la R_{sg} a partir de modelos digitales de elevaciones y de datos astronómicos, factores en los que se apoyan otros autores (de la Casa et al., 2003; Gómez-Tagle, 2003). También se han propuesto modelos estructurales basados en el tratamiento estadístico series de radiación generadas con modelos de simulación a escala horaria (Aguiar and Collares, 1992), y diaria (Ávila et al., 2000).

En la gestión del territorio del medio rural es común disponer únicamente de los valores registrados en estaciones termopluviométricas, y en tales casos, para la estimación de variables de gran importancia en la planificación agraria tales como la evapotranspiración de referencia (ET_o) y/o R_{sg} , se suele recurrir a modelos de basados en la ecuación de Hargreaves (Hargreaves and Samani, 1985; Trajkovic, 2007).

Durante la última década, se ha extendido el uso de las redes neuronales artificiales (RNAs), como herramienta para la estimación de parámetros entre los que existe correlación espacial y/o temporal, y han sido aplicadas con resultados satisfactorios en el campo de la agrometeorología. Por ejemplo, la temperatura del aire, la humedad relativa, la presión de vapor de saturación, la temperatura del punto de rocío, y especialmente en la estimación de la ET_o , con frecuencia en situaciones con limitación de datos (Shank, 2003; Zanetti et al., 2007; Kumar et al., 2010). En el ámbito de la radiación solar existen trabajos que han aplicado estas técnicas para su estimación (Dorvlo et al., 2002; Krishnaiah et al., 2007; Rehman and Mohandes, 2008; Jiang, 2008).

Por otra parte, es fundamental en numerosas tareas de planificación hidrológica, agrícola o urbanística, disponer de la información meteorológica representada espacialmente.

Existen diferentes métodos para la realización de cartografías climáticas. Los métodos tradicionales, basados en un criterio experto y realización manual de las cartografías (de León et al., 1974; Elías y Ruiz-Beltrán, 1981), han dado paso a técnicas basadas en procedimientos estadísticos y de cartografiado automático (Rehman and Ghori, 2000; Harold, 2004; DMAGA, 2008; Alsamamra et al., 2009).

El objetivo del presente trabajo es el desarrollo en Castilla-La Mancha (C-LM) de modelos espaciales de estimación de R_{sg} mensual basados en ANN y ecuaciones alternativas con bajos requerimientos de datos (estaciones termopluviométricas). Con esta información se procede a la representación gráfica de la variabilidad espacial y temporal de los datos climáticos generados.

Materiales y métodos

Descripción de la zona de estudio

El área de estudio es la Comunidad Autónoma de C-LM, región semiárida con una extensión de 79.462 km². Está ubicada en el centro de la Península Ibérica, rodeada por una serie de montañas, que tienen una influencia significativa en las condiciones climáticas de la región. Las dos terceras partes del territorio están por encima de los 600 m de altura sobre el nivel del mar, mientras que no hay ninguna zona que se encuentre situada a menos de 200 m de altitud. Además, esta región tiene una alta variabilidad climática debido a la presencia de llanuras (predominantes) y montañas.

El clima regional se puede clasificar, por sus características en conjunto, como mediterráneo, con un marcado matiz continental, con contrastes térmicos notables, diarios y estacionales, de verano largo, seco y caluroso e invierno con muchos días de heladas, espe-

cialmente en tierras altas y hondonadas, y con una distribución estacional desequilibrada de las escasas lluvias. Aún así, existen dos zonas climáticas claramente diferenciadas: Un sector húmedo con un superávit de 230 a 560 mm, localizado principalmente en el norte de la región en las áreas de mayor altitud, y un sector seco, con un déficit que con frecuencia supera los 400 mm en un período de entre 7 y 9 meses. La última es la más representativa y amplia de la región, situada en su mayor parte en la llanura central y el área Sur y Oriental. La Figura 1 presenta la temperatura media anual de la región (Martínez-Romero, 2010) a modo de resumen de las características generales de las condiciones termométricas de C-LM.

La R_{sg} anual acumulada en C-LM oscila entre los 5.500 MJ m^{-2} en el Noreste y los 6.500 MJ m^{-2} en áreas del sur y sureste (Martínez-Romero, 2010). Como referencia se suele tomar el valor promedio diario de $16,5 \text{ MJ m}^{-2} \text{ día}^{-1}$ (MMA, 2008). Los mínimos valores de R_{sg} promedio diaria en un mes se producen durante diciembre en el Norte y Noroeste de C-LM ($6,5 \text{ MJ m}^{-2} \text{ día}^{-1}$), y los máximos durante julio en el Sur y Suroeste ($28,5 \text{ MJ m}^{-2} \text{ día}^{-1}$). La disminución de la R_{sg} es gradual desde el sureste y suroeste hacia el Noreste de la región, con diferencias más acentuadas en las proximidades de las sierras del Norte y Noreste.

En la región de C-LM se dispone de series históricas de datos de temperatura y precipitación mensuales procedentes de 132 estaciones meteorológicas manuales (Fig. 1), que fueron instaladas por el Instituto Nacional de Meteorología. Esta información puede ser insuficiente si se pretende realizar un estudio en profundidad del clima de la región. Los datos mínimos necesarios para la estimación de la R_{sg} son la temperatura máxima (T_{max}) y la temperatura mínima (T_{min}) (Hargreaves and Samani, 1985; Allen et al., 1998), los cuales se encuentran disponibles en estas estaciones termoplumiométricas.

Además, en la región se dispone de 44 estaciones agroclimáticas completas (Fig. 1), incluidas en la red del Servicio de Información Agroclimática para el Regadío (SIAR). Éstas tienen incorporado un piranómetro Sky modelo SP1110 (Campbell) que registra los valores de radiación global incidente cada 10 segundos, quedando almacenados por el datalogger en períodos semihorarios. Esta red se instaló a partir del año 2000 y por ello sus series temporales de datos son más cortas.

Metodología general propuesta

Se plantea la estimación de valores promedio mensuales de R_{sg} a partir de los registros disponibles en series históricas de estaciones termoplumiométricas aplicando modelos regionales generados mediante técnicas de regresión lineal (RL) y redes neuronales artificiales (RNAs) (von Storch and Zwiers, 1999; Schalkoff, 1997; Nabney, 2001). En primer lugar se ha procedido al filtrado de los registros (Aguilar et al., 2003), proceso en el que se han detectado y eliminado los datos anómalos. Combinando los datos de R_a y/o los registros de T_{max} , T_{min} , y/o P se han planteado 15 modelos de RNAs o RLs definidos por 1, 2, 3 o 4 variables independientes.

Paralelamente, se valoran los resultados obtenidos al aplicar la ecuación propuesta por Hargreaves (Hargreaves y Samani, 1985) y recomendada por FAO en condiciones de limitación de registros para la estimación de la R_{sg} (Allen et al., 1998) (Ec. 1). Este método se justifica en el hecho de que las diferencias entre el máximo y mínimo de temperaturas se relacionan estrechamente con la radiación solar diaria existente en una dada localización. Por ello, este método estima la R_{sg} a partir de dichas diferencias y de la radiación extraterrestre (R_a), que sólo depende de la latitud (Ec. 1):

$$R_s = k_{R_s} \sqrt{(T_{max} - T_{min})} R_a \quad [1]$$

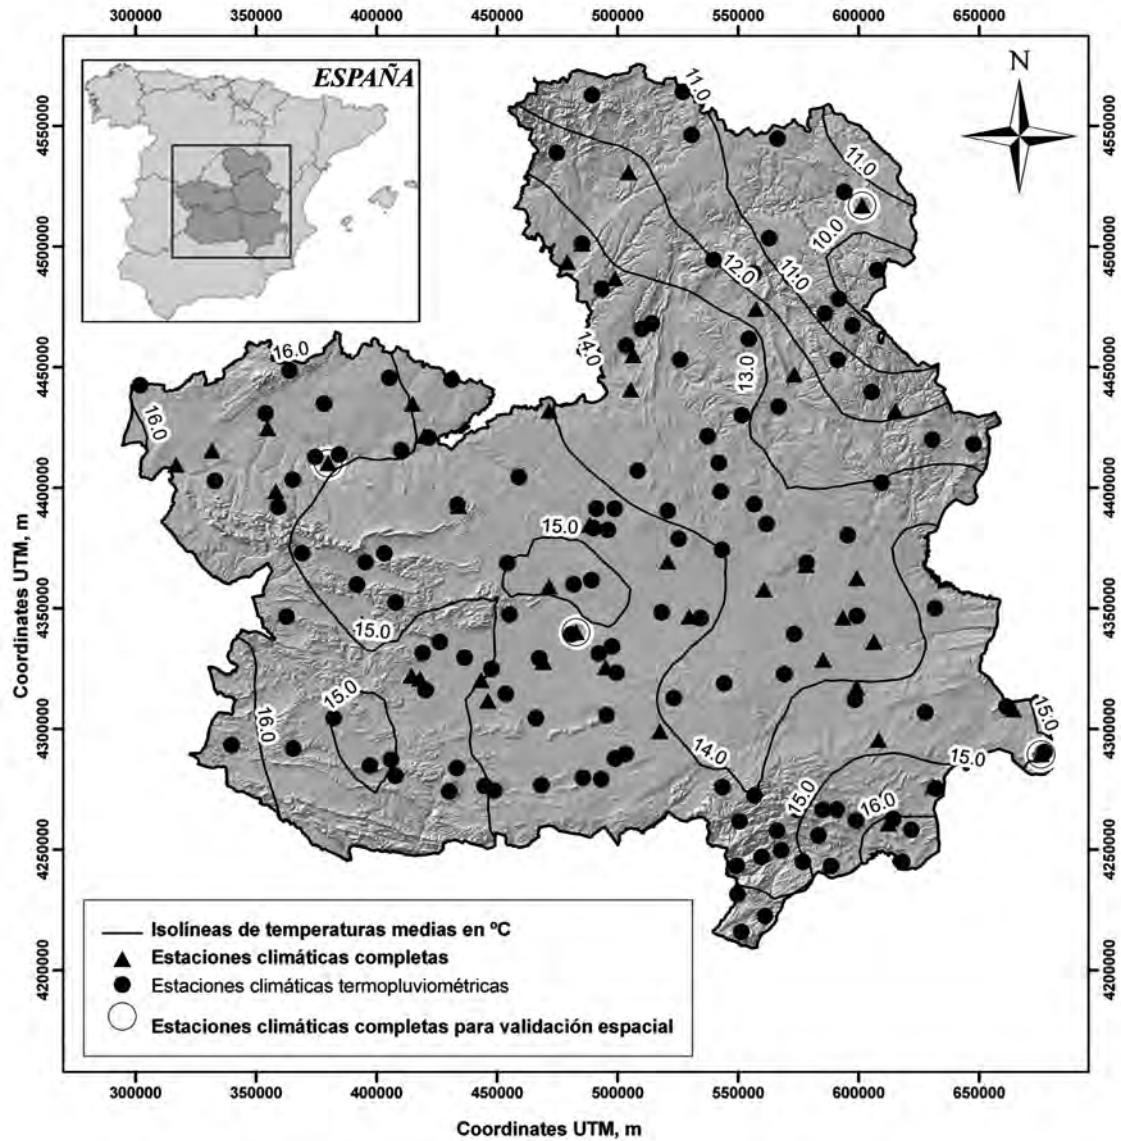


Figura 1. Localización de la región de Castilla-La Mancha y de las estaciones agroclimáticas completas. Distribución de las temperaturas medias anuales (°C) para la serie 1981-2000.

Fuente: Martínez-Romero (2010).

Figure 1. Location of the Region of Castilla-La Mancha and of the completed weather stations. Distribution of annual average temperatures (°C) during the time series 1981-2000.

Source: Martínez-Romero (2010).

donde: R_a es la radiación extraterrestre ($\text{MJ m}^{-2} \text{ día}^{-1}$); T_{max} es la temperatura máxima del aire ($^{\circ}\text{C}$); T_{min} es la temperatura mínima del aire ($^{\circ}\text{C}$); y es un coeficiente de ajuste que varía entre 0,16 y 0,19 ($^{\circ}\text{C}^{-0.5}$) ($k_{R_s} \approx 0,16$, para zonas de interior y $k_{R_s} \approx 0,19$, para zonas costeras donde las masas de aire están fuertemente influenciadas por una gran masa de agua).

La Figura 2 presenta las etapas seguidas en la calibración y validación de los diferentes modelos para lo cual se han usado los valores registrados en las 44 estaciones completas de la red SIAR ubicadas en C-LM (Fig. 1) (CREA, 2009). Por otra parte, para el modelo de Hargreaves se estudió la calibración del coeficiente de ajuste. Por último, en el proceso de validación se contrastaron estadísticamente

los resultados estimados por los distintos modelos con los valores observados en las estaciones completas.

De entre todos los modelos propuestos se seleccionará uno, cuya aplicación permitirá la estimación puntual de la R_{sg} promedio mensual en el ámbito de C-LM a partir de los registros históricos disponibles en 132 estaciones meteorológicas manuales. Mediante la aplicación de una de las técnicas de geoestadística (KS) (Webster y Oliver, 2001) se elaboró una salida gráfica en forma de mapas que caracteriza este parámetro climático en C-LM. Para ello se elaboraron 17 mapas, 1 con datos del promedio anual de la serie, 4 con el promedio estacional (primavera, verano, otoño e invierno) y 12 con el promedio mensual.

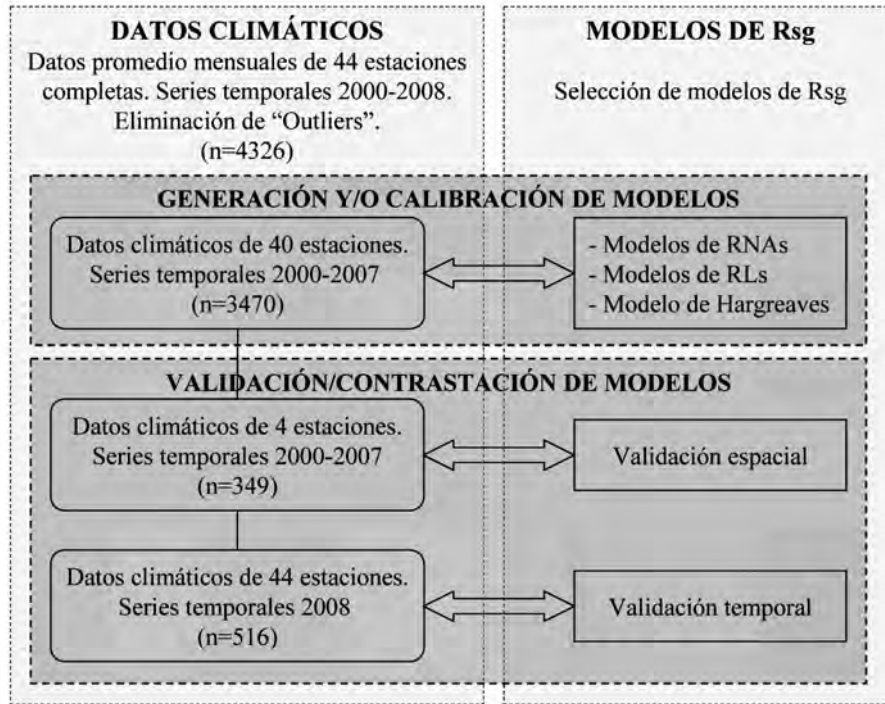


Figura 2. Diagrama de la metodología propuesta para la calibración y validación de modelos. donde: n = número de datos; R_{sg} = radiación solar global; RNAs = redes neuronales Artificiales, RLs = Regresiones lineales.

Figure 2. Diagram of the proposed methodology for calibration and validation of the models. where: n = data number, R_{sg} = global solar radiation, RNAs = artificial neural networks, RLs = Linear regression.

Modelos basados en regresiones lineales

La técnica de la RL se ha aplicado siguiendo una pauta de complejidad creciente (entendida como el aumento del número de variables independientes) en los modelos planteados, de acuerdo con la metodología de la regresión stepwise ("paso a paso") (Hocking, 1976). Esto permite contrastar la mejora en la bondad de los ajustes en función de la complejidad del modelo de RL. Las variables independientes introducidas paso a paso son los valores promedio mensuales de las temperaturas y precipitación (P) registrados en las estaciones de la red SIAR (Fig. 1) y la radiación solar extraterrestre (R_a , valores para R_a calculados en el día 15 del mes, Allen et al., 1998).

Modelos basados en estructuras de RNAs

También se ha planteado el uso de herramientas basadas en RNAs (Schalkoff, 1997; Nabney, 2001) para la modelación de la R_{sg} mensual. Tal como se ha descrito para las técnicas de RL, se han creado modelos crecientes en complejidad, con una, dos o tres variables independientes, que en este caso definen la capa de entrada. En la Figura 3 se esquematiza la estructura de RNA utilizada, definida por tres grupos de neuronas que conforman las capas de entrada, la capa oculta y la de salida. Los datos de entrada (T_{max} y/o T_{min} y/o P y/o R_a) se representan en la Figura 3 como x_n (para $n = 1, 2, 3, 4$). Cada neurona implementa una función local; así, en los nudos de entrada

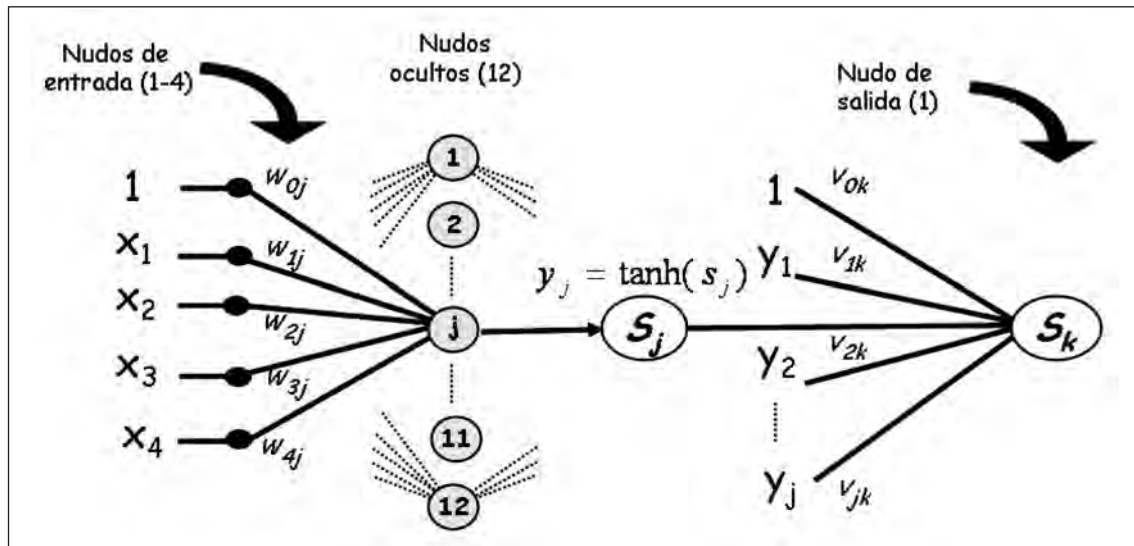


Figura 3. Estructura de la red neuronal artificial utilizada.
(El significado de los símbolos de esta Figura se detalla en el texto)

Figure 3. Artificial neural network structure used.

where: x_n (for $n = 1, 2, 3, 4$) are the input data (Maximum temperatures and/or minimum and/or average and/or rainfall and/or extraterrestrial radiation); w_{nj} , v_{jk} ($j, k = 1, 2, \dots, 12$) represent the weights associated with data matrices of the first and second layer respectively and biases in the linear activation functions; s_j is the result of the linear transformation of activation; y_j is the result of the nonlinear transformation of data; s_k is the output value (Global solar radiation).

es una función lineal, en los ocultos una no lineal, y en los de salida, de nuevo una lineal (Schalkoff, 1997; Nabney, 2001). Los pesos asociados a las matrices de datos de la primera y segunda capa, y, los sesgos en las funciones lineales de activación se representan respectivamente como w_{nj} , v_{jk} ($j, k = 1, 2, \dots, 12$). Los valores respectivos resultantes de las transformaciones lineal y no lineal de los datos se representan como S_j e y_i . S_k representa el valor de salida, en este caso la R_{sg} .

Los datos climáticos utilizados para la calibración y validación de los modelos son los mismos que en el caso de las RLs. La estructura RNA seleccionada se define mediante el uso de gráficos de superficie de respuesta (Martínez-Romero et al., 2010).

Estadísticos de comparación. Bondad en el ajuste de los modelos.

Para contrastar y validar los distintos modelos (RLs, RNAs y modelo de Hargreaves (Ec. 1) se han utilizado diversos parámetros estadísticos (Willmott, 1982): el coeficiente de determinación (R^2), raíz cuadrada del error cuadrático medio (RMSE), error relativo (ER), y el índice de similitud (IS) (Ecs. 2 a 4). En todos los casos, los datos de referencia (variable observada) son los valores del promedio mensuales de R_{sg} calculados a partir de los datos semihorarios procedentes de observaciones directas con los piranómetros instalados en las estaciones SIAR, con rangos de medida entre 300 y 1100 mm y una precisión del 3%. Las ecuaciones que definen estos estadísticos son:

$$RMSE = \left[n^{-1} \sum (P_i - O_i)^2 \right]^{1/2} \quad [2]$$

donde: RMSE, es la raíz cuadrada del error cuadrático medio; n , es el número de observaciones; P_i y O_i , son los valores de las observaciones comparadas (valores observados de la variable dependiente (O_i) y valores predichos o estimados con el modelo (P_i)).

$$ER = (RMSE / O_{med}) \cdot 100 \quad [3]$$

donde: ER, es el error relativo y se estima como un porcentaje del valor medio de la variable; O_{med} , es el valor medio de la variable observada.

$$IS = 1 - \left[\frac{\sum (P_i - O_i)^2}{\sum ((P_i - O_{med}) + (O_i - O_{med}))^2} \right] \quad [4]$$

donde: IS, es el índice de similitud y se expresa como una medida relativa de la diferencia entre variables; si $IS = 1$, existe un acuerdo perfecto entre P y O .

En los modelos lineales, para determinar la capacidad de predicción del modelo o bondad de ajuste además del R^2 se han tenido en cuenta en cuenta los grados de significación, tanto de los modelos como de los coeficientes o parámetros que acompañan a las variables independientes y a la constante, calificándolos de altamente significativos, para $p < 0,01$, y no significativos, cuando $p > 0,1$. Para servir de apoyo en la decisión sobre la bondad de los modelos se han estimado también estadísticos (Ecs. 5 a 7) definidos por las siguientes expresiones matemáticas:

$$SEE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n - n_{ind}}} \quad [5]$$

donde: SEE, es el error estándar de estimación y explica el valor de la desviación estándar de los residuos, la variabilidad, o dispersión, de los valores observados alrededor de la recta de regresión; n , es el número de observaciones; P_i y O_i , son los valores de las observaciones comparadas (valores observados de la variable dependiente (O_i) y valores predichos o estimados con el modelo (P_i)); n_{ind} , es el número de variables independientes.

$$MAE = \frac{\sum_{i=1}^n |(P_i - O_i)|}{n} \quad [6]$$

donde: MAE, es el error medio absoluto.

$$CMR = \frac{\sum_{i=1}^n (P_i - O_{med})^2}{n - n_{ind}} \quad [7]$$

donde: CMR, es el cuadrado medio residual.

Además se han analizado gráficamente los residuos para estudiar la homoscedasticidad y el ajuste a la normal de los datos así como la independencia de los residuos (Luque, 2000; Coll y Guijarro, 2007; von Storch and Zwiers, 1999).

Representación cartográfica de la R_{sg}.

Finalmente, se dispone de datos de temperaturas promedio mensuales para el período que comprende los años 1981 a 2000 en 132 ubicadas en C-LM (Fig. 1). A partir de estos registros de temperatura se estimó la R_{sg} mediante la aplicación del modelo seleccionado. Para ofrecer una salida gráfica a los datos generados se ha realizado la interpolación aplicando la técnica de kriging simple (KS).

El análisis geoestadístico de un conjunto de datos lleva implícito unos pasos encaminados a ofrecer los mejores modelos de predicción o interpolación (Webster and Oliver, 2001). El análisis geoestadístico propiamente dicho, tras el análisis exploratorio de los datos, incluye los siguientes pasos (Martínez-Cob et al., 1994; Webster and Oliver, 2001): 1) modelización y validación de los semivariogramas; 2) kriging; y 3) elaboración de mapas de isóneas de las estimas. Estas etapas, que coinciden en aceptar numerosos autores, se encuentran descritas más ampliamente en diversos manuales (Isaaks y Srivastava, 1989; Samper y Carrera, 1990; Olea, 1999).

En el presente estudio se ha aplicado la técnica de KS meramente como una herra-

mienta gráfica. El KS es una forma básica de kriging en la que se generaliza una regresión lineal para la estimación de un atributo espacial continuo, a partir de la formulación de un estimador óptimo, que minimice el error cuadrático medio.

Una amplia descripción de las hipótesis asumidas en estos modelos, la definición del estimador, el proceso de la estimación de la varianza y del mínimo error, así como las ecuaciones y algoritmo de aplicación queda definida por: Samper y Carrera, (1990), de Fouquet (1996), Olea (1999).

Resultados y discusión

Estimación de la R_{sg} mediante la ecuación propuesta por FAO

El valor de K_{Rs} obtenido durante la calibración fue de 0,15928 que apenas difiere del de 0,16 sugerido por la FAO. Así, para las validaciones espacial y temporal, se ha utilizado un K_{Rs} = 0,16. La Tabla 1 lista los resultados de la evaluación del modelo de Hargreaves (R_{sgH}) (Ec. 1).

Los valores de RMSE durante la validación fueron de 1,23 MJ m⁻² día⁻¹ (validación espacial) y 1,66 MJ m⁻² día⁻¹ (validación temporal). El valor de RMSE durante la calibración fue de 1,43 MJ m⁻² día⁻¹. En C-LM, el ER se cifra entre el 7,1% y el 9,7%. La incertidumbre del R_{sgH} es baja, ya que está limitada a menos del 10% (ER se cifra entre el 7,1% y el 9,7%). Aún así, sería deseable desarrollar otros modelos que pudieran reducir esa incertidumbre. El desarrollo de los mismos, podría tener mayor interés en zonas con características climáticas distintas. Así, Gavilán (2010) estima errores cercanos al 20% en zonas de litoral.

Tabla 1. Resultados comparativos de la aplicación del modelo de Hargreaves para la estimación de la radiación solar global en Castilla-La Mancha (C-LM)
 Table 1. Comparative results of the implementation of the Hargreaves model for estimating global solar radiation in Castilla-La Mancha (C-LM)

Parámetros descriptivos	Datos de calibración	Datos de validación espacial	Datos de validación temporal
Número de estaciones	44	4	44
Número de datos	3.470	349	516
Media de los valores observados (MJ m ⁻² día ⁻¹)	17,17	17,35	17,11
Media de los valores estimados (MJ m ⁻² día ⁻¹)	17,21	17,53	17,20
Media de los valores observados/ media de los valores estimados	1,00	1,01	1,01
R ² ajustado	0,96	0,97	0,95
RMSE (MJ m ⁻² día ⁻¹)	1,43	1,23	1,66
ER (%)	8,34	7,12	9,68
IS	0,99	0,99	0,99
R _{sg} anual acumulada (MJ m ⁻²)	6.282	6.398	6.278

x, valores observados; y, valores predichos; R², Coeficiente de determinación; RMSE, Raíz del Error Cuadrático Medio; ER, Error relativo; IS, Índice de Similitud.

Estimación de la R_{sg} mediante la aplicación de modelos de regresión lineal

La Tabla 2 resume cuatro modelos de RL (con 1, 2, 3 y 4 variables independientes) seleccionados de entre los 15 analizados y su bondad en el ajuste al realizar la introducción en los mismos de las variables independientes "paso a paso". Como se ha indicado, los registros climáticos utilizados en los modelos planteados son: T_{max}, T_{med}, T_{min}, P y R_a. La variable dependiente es para todos los modelos, la radiación solar global (R_{sg}), comparando los valores estimados con los observados en las estaciones de la red SIAR. De los cuatro modelos de la Tabla 2, se han utilizado el A, B y C para comparar la estimación de la R_{sg} en la región con 1, 2 o 3 variables independientes

respectivamente. La P no es incluida como variable en ninguno de ellos. Aunque en el modelo C se califica como altamente significativa, la mejora de los resultados con respecto al modelo B (tres variables independientes) es prácticamente inapreciable. Este hecho podría deberse a la escala de tiempo utilizada (mensual), donde la repercusión en el valor promedio mensual de una bajada puntual de la radiación incidente en los días de precipitación, parece ser baja.

En la Tabla 3 se recogen los estadísticos descriptivos calculados tras aplicar los tres modelos de regresión lineal seleccionados (Tabla 2) para estimar la R_{sg} en C-LM. El modelo C (equiparable al de R_{sgH}) ofrece RMSEs de 1,08 MJ m⁻² día⁻¹, y, 1,69 MJ m⁻² día⁻¹, para las validaciones espacial y temporal respectiva-

Tabla 2. Modelos seleccionados para la estimación de la radiación solar global aplicando regresiones lineales mediante el método Stepwise. Estadísticos descriptivos
 Table 2. Selected models for estimating global solar radiation using linear regressions Stepwise. Descriptive statistics

Estadísticos	Modelo A	Modelo B	Modelo C	Modelo D
	1 variable ⁽¹⁾	2 variables ⁽²⁾	3 variables ⁽³⁾	4 variables ⁽⁴⁾
Variable independiente seleccionada	T_{max}	T_{max}, R_a	T_{max}, R_a, T_{min}	T_{max}, R_a, T_{min}, P
p- valor	0,00	0,00	0,00	0,00
R ² Ajustado (%)	81(***)	96(***)	97(***)	97(***)
RMSE (MJ m ⁻² día ⁻¹)	3,35	1,46	1,31	1,31
Error relativo (%)	19,53	8,49	7,63	7,61
Índice de similitud	0,94	0,99	0,99	0,99
Error standard (MJ m ⁻² día ⁻¹)	3,35	1,46	1,31	1,30
Media del error absoluto (MJ m ⁻² día ⁻¹)	2,81	1,17	1,02	1,01
Cuadrado medio residual (MJ m ⁻² día ⁻¹) (gl)	11,33 (3,468)	5,52 (3,468)	5,07 (3,468)	5,03 (3,468)
Coficiente curtosis	2,23	3,02	3,51	3,55
Coficiente Asimetría	0,20	0,00	-0,05	0,09

$$(1) R_{sg} = 0,827563(***)T_{max}$$

$$(2) R_{sg} = -3,6037(***) + 0,550031(***)T_{max} - 0,332065(***)R_a$$

$$(3) R_{sg} = -5,997(***) + 0,791818(***)T_{max} + 0,316956(***)R_a - 0,328023(***)T_{min}$$

$$(4) R_{sg} = -4,8748(***) + 0,381778(***)T_{max} + 0,5738(***)R_a - 0,230489(***)T_{min} - 0,0144162(***)P$$

R_{sg} , radiación solar global (MJ m⁻² día⁻¹); T_{max} , temperatura máxima (°C); T_{min} , temperatura mínima (°C); R_a , radiación solar extraterrestre (MJ m⁻² día⁻¹); P, precipitación (mm/mes); R², coeficiente de determinación; (***) = p-valor < 0,01 (altamente significativo).

mente. Los ERs para los mismos supuestos, son del 9,9% y 6,2%. Para el resto de modelos los errores son superiores, ligeramente en la RL que requiere de datos de T_{max} y R_a (entre el 1% y 2% superior) y con mayor diferencia en la RL simple (ER próximo al 20%). El modelo D, que incorpora las cuatro variables independientes, no ofrece mejores resultados que un modelo más sencillo como es el C.

Estimación de la R_{sg} mediante el uso de RNAs

La estructura de RNAs utilizada para el análisis previo de los resultados fue la definida por 10 nudos y 2500 iteraciones, evitando una estructura demasiado sencilla, que pueda conducir a errores en los resultados, y una compleja, que pueda ofrecer problemas de

Tabla 3. Resultados comparativos de la aplicación de modelos de regresión lineal para la estimación de la radiación solar global en Castilla-La Mancha (C-LM)

Table 3. Comparative results of the application of linear regression models for estimating global radiation in Castilla-La Mancha

Parámetros descriptivos	Datos de calibración ⁽¹⁾	Datos de validación espacial	Datos de validación temporal
Número de estaciones	44	4	44
Número de datos	3.470	349	516
Media de los valores observados (MJ m ⁻² y día ⁻¹)	17,17	17,35	17,11
Regresión lineal función de T _{max}			
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,25	17,14	16,83
Media de los valores observados / media de los valores estimados	1,00	0,99	0,98
R ² ajustado	0,81	0,78	0,82
RMSE (MJ m ⁻² y día ⁻¹)	3,35	3,48	3,20
ER (%)	19,53	20,07	18,68
IS	0,94	0,94	0,94
R _{sg} anual acumulada (MJ m ⁻²)	6.296	6.256	6.143
Regresión lineal función de T _{max} y R _a			
Parámetros descriptivos	Datos de calibración ⁽¹⁾	Datos de validación espacial	Datos de validación temporal
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,17	17,22	17,19
Media de los valores observados / media de los valores estimados	1,00	0,99	1,00
R ² ajustado	0,96	0,97	0,93
RMSE (MJ m ⁻² y día ⁻¹)	1,46	1,35	1,89
ER (%)	8,49	7,79	11,03
IS	0,99	0,99	0,98
R _{sg} anual acumulada (MJ m ⁻²)	6.267	6.285	6.274
Regresión lineal función de T _{max} , R _a y T _{min}			
Parámetros descriptivos	Datos de calibración ⁽¹⁾	Datos de validación espacial	Datos de validación temporal
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,17	17,35	17,18
Media de los valores observados / media de los valores estimados	1,00	1,00	1,00
R ² ajustado	0,97	0,98	0,95
RMSE (MJ m ⁻² y día ⁻¹)	1,31	1,08	1,69
ER (%)	7,63	6,21	9,88
IS	0,99	0,99	0,99
R _{sg} anual acumulada (MJ m ⁻²)	6.267	6.333	6.271

⁽¹⁾ Los datos de calibración son los utilizados para desarrollar los modelos de regresión lineal y posteriormente los de Redes Neuronales Artificiales.

T_{max}, Temperatura máxima promedio mensual; T_{min}, Temperatura mínima promedio mensual; R_a, radiación solar global extraterrestre; R², Coeficiente de determinación; RMSE, Raíz del Error Cuadrático Medio; ER, Error relativo; IS, Índice de Similitud.

sobrealimentación de la red, falseando también los resultados (Lawrence *et al.*, 1997).

En el caso estudiado, específicamente para el modelo C, que requiere datos de T_{\max} , T_{\min} y R_a , el uso de gráficos de superficie de respuesta, ha permitido el estudio de la evolución del RMSE de un gran número de estructuras (Martínez-Romero, 2010). La Figura 4 muestra los gráficos de superficie de respuesta analizados, donde se muestra la evolución del RMSE para 20.000 estructuras de

RNAs definidas entre 1 y 1.000 iteraciones y entre 1 y 20 nudos. Analizados en común los datos de validación espacial (Fig. 4a) y temporal (Fig. 4b), se pueden observar problemas de sobrealimentación en el segundo caso, con las estructuras más complejas. También se detectan problemas de falta de precisión con estructuras definidas por un número de iteraciones menor de 100 y un número de nudos inferior a 4, este último supuesto para los datos de validación temporal.

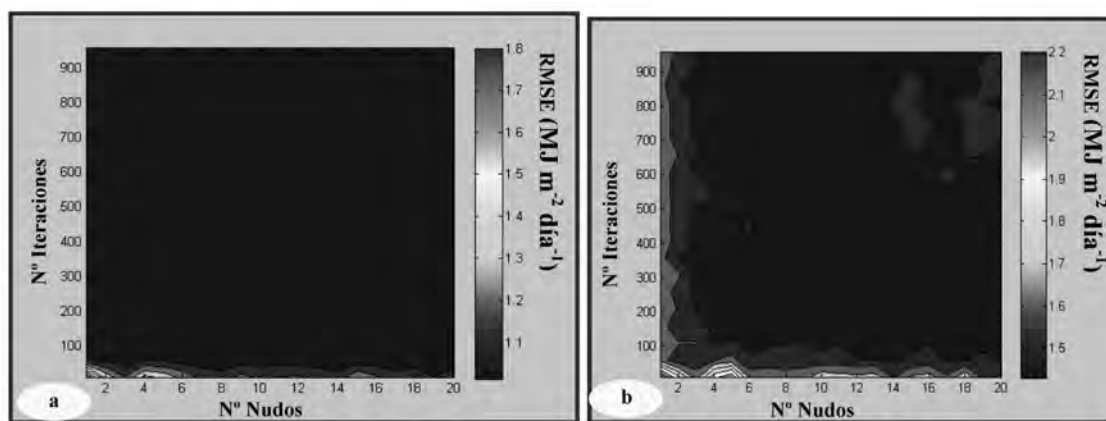


Figura 4. Gráficos de superficie de respuesta de la evolución de la Raíz del Error Cuadrático Medio (RMSE) en función de la estructura de red neuronal utilizada, para la estimación de la radiación solar global en Castilla-La Mancha: a) validación espacial ($n = 349$ datos), b) validación temporal ($n = 516$ datos).

Figure 4. Response surface graphs of the evolution of the Root Mean Square Error (RMSE) based on neural network structure used for the estimation of global solar radiation in Castilla-La Mancha: a) spatial validation ($n = 349$ data), b) temporal validation ($n = 516$ data).

Teniendo presente lo expuesto, para este modelo de RNA, se ha seleccionado la estructura definida por 12 nudos y 210 iteraciones. Los errores de validación espacial y temporal esperables se estiman respectivamente en $1,0 \text{ MJ m}^{-2} \text{ día}^{-1}$, y $1,4 \text{ MJ m}^{-2} \text{ día}^{-1}$. No existe una metodología establecida que permita determinar de modo exacto el número de capas ocultas, por lo que generalmente se determinan por un procedimiento de ensayo y

error (Ritchie *et al.*, 2003; Xu and Ling, 2008). Algunos autores que han trabajado con parámetros climáticos recomiendan el uso de una RNA simple (es decir, bajo número de neuronas ocultas) (Dai *et al.*, 2008). Así, diversos autores consideran un número óptimo de nudos ocultos entre los 4 y los 10 (Zanetti, *et al.*, 2007; Dai *et al.*, 2008; Kumar *et al.* 2008). La selección de una red con una capa oculta coincide con los resultados de au-

tores tales como Kumar et al. (2002) o Zanetti et al., (2007), que concluyeron que una RNA con una sola capa oculta es suficiente para representar las relaciones no lineales entre los elementos climáticos.

Tal como se presentó en las Tablas 1 y 3, la Tabla 4 expone los resultados comparativos en estimación de la R_{sg} en C-LM, en este caso mediante técnicas basadas en RNAs.

Comparación de los distintos modelos para la estimación de la R_{sg}

En la Tabla 5 se recopilan a modo de resumen los errores de calibración y validación (como RMSE) estimados para cada uno de los modelos regionales seleccionados y estudiados en función de las variables incluidas en los mismos. Para los modelos que requieren datos de las variables T_{max} , T_{min} y R_a , se muestra también el ER y la diferencia en éste al aplicar el modelo recomendado por FAO o la RNA.

Tal como se muestra en la Tabla 3, la estimación de la R_{sg} mediante RNAs ofrece resultados más ajustados a los valores observados que a partir de RLs, para cualquier supuesto. El análisis estadístico de los resultados ofrecidos por el modelo de Hargreaves y las RNAs, no ofrece grandes diferencias en las validaciones espacial y temporal, aunque esta última metodología permite reducir el ER en valores próximos al 1,5%. Así, los modelos con menor error son los modelos desarrollados mediante la aplicación de RNAs con datos de T_{max} , T_{min} y R_a , y quedan acotados entre el 5,8% y el 8,3%, equivalente a $1,0 \text{ MJ m}^{-2} \text{ día}^{-1}$, y, $\text{MJ m}^{-2} \text{ día}^{-1} \text{ día}$.

Representación cartográfica de la R_{sg} en C-LM

Los datos de R_{sg} utilizados para la interpolación corresponden para cada estación climática, al valor promedio de la serie 1981-2000

calculados mediante técnicas de RNAs con datos de T_{max} , T_{min} y R_a .

Con una media estimada para todas las localizaciones de $17 \text{ MJ m}^{-2} \text{ día}^{-1}$, la desviación estándar es de $0,78 \text{ MJ m}^{-2} \text{ día}^{-1}$, y el Coeficiente de Variación de 4,58%. Los histogramas de frecuencia y gráficos de ajuste a la normal para los datos de R_{sg} muestran la presencia de valores extremos en las colas, que coinciden con estaciones ubicadas en las áreas periféricas de la región, principalmente en zonas de sierra. Por otra parte, los análisis de los semivariogramas no evidencian para los datos de R_{sg} la presencia de valores anómalos o fuera de rango, y los semivariogramas empíricos omnidireccionales se han ajustado automáticamente al modelo esférico. La técnica de KS se ha utilizado como herramienta para generar una salida gráfica a los datos de R_{sg} . Con respecto a los valores de los parámetros que definen los modelos matemáticos ajustados a los semivariogramas experimentales y los estadísticos de validación cruzada, cabe reseñar que los mismos ofrecen resultados que corroboran la idoneidad de los modelos: promedio de errores observados (ME) y estandarizados próximos a cero, elevada similitud entre los valores predichos y observados (contrastación entre el RMSE y la media de los errores estándar promedio), y, RMSE estandarizados próximos a la unidad. En la Tabla 6, pueden consultarse los valores de dichos parámetros, correspondientes a las R_{sg} promedio anuales y estacionales.

La Figura 5 presenta, para CLM, el mapa de la R_{sg} promedio diaria anual sobre una superficie horizontal basado en el modelo definido en la Tabla 6. La oscilación en la región es de, aproximadamente, $2 \text{ MJ m}^{-2} \text{ día}^{-1}$, con valores mínimos cercanos a los $15,5 \text{ MJ m}^{-2} \text{ día}^{-1}$ y máximos de $17,5 \text{ MJ m}^{-2} \text{ día}^{-1}$, llegando a $18 \text{ MJ m}^{-2} \text{ día}^{-1}$ en localizaciones puntuales.

En el Norte y Nordeste de la región, en el área delimitada por latitudes superiores a

Tabla 4. Resultados comparativos de la aplicación de modelos basados redes neuronales artificiales para la estimación de la radiación solar global en Castilla-La Mancha (C-LM)

Table 4. Comparative results of the application of artificial neural networks models for estimating global solar radiation in Castilla-La Mancha (C-LM)

Parámetros descriptivos	Datos de calibración	Datos de validación espacial	Datos de validación temporal
Número de estaciones	44	4	44
Número de datos	3.470	349	516
Media de los valores observados (MJ m ⁻² y día ⁻¹)	17,17	17,35	17,11
Red neuronal artificial función de T _{max} (10 nudos y 2500 iteraciones)			
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,17	17,09	16,92
Media de los valores observados / media de los valores estimados	1,00	0,99	0,99
R ² ajustado	0,83	0,79	0,82
RMSE (MJ m ⁻² y día ⁻¹)	3,18	3,46	3,11
ER (%)	18,51	19,93	18,17
IS	0,95	0,94	0,95
R _{sg} anual acumulada (MJ m ⁻²)	6.267	6.238	6.176
Red neuronal artificial función de T _{max} y R _a (10 nudos y 2500 iteraciones)			
Parámetros descriptivos	Datos de calibración	Datos de validación espacial	Datos de validación temporal
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,17	17,18	17,14
Media de los valores observados / media de los valores estimados	1,00	0,99	1,00
R ² ajustado	0,97	0,97	0,96
RMSE (MJ m ⁻² y día ⁻¹)	1,27	1,25	1,56
ER (%)	7,42	7,23	9,12
IS	0,99	0,99	0,99
R _{sg} anual acumulada (MJ m ⁻²)	6.267	6.271	6.256
Red neuronal artificial función de T _{max} , R _a y T _{min} (12 nudos y 210 iteraciones)			
Parámetros descriptivos	Datos de calibración	Datos de validación espacial	Datos de validación temporal
Media de los valores estimados (MJ m ⁻² y día ⁻¹)	17,17	17,28	17,11
Media de los valores observados / media de los valores estimados	1,00	1,00	1,00
R ² ajustado	0,98	0,98	0,96
RMSE (MJ m ⁻² y día ⁻¹)	1,17	1,00	1,42
ER (%)	6,79	5,75	8,29
IS	0,99	1,00	0,99
R _{sg} anual acumulada (MJ m ⁻²)	6.267	6.307	6.245

T_{max}, Temperatura máxima promedio mensual; T_{min}, Temperatura mínima promedio mensual; R_a, radiación solar global extraterrestre; R², Coeficiente de determinación; RMSE, Raíz del Error Cuadrático Medio; ER, Error relativo; IS, Índice de Similitud.

Tabla 5. Errores estimados para distintos modelos de regresión lineal, modelo de Hargreaves y redes neuronales artificiales (RNAs) en Castilla-La Mancha para la estimación de la radiación solar global
Table 5. Estimated errors for several regression models, the Hargreaves model and artificial neural networks (ANNs) in Castilla-La Mancha for estimating global solar radiation

Datos utilizados	Modelo	Variables independientes				⁽¹⁾ Diferencia ER Hargreaves - RNA
		T_{max}	T_{max} , R_a	T_{max} , T_{min} , R_a		
		RMSE (MJ m ⁻² día ⁻¹)		ER (%)		
Calibración	Regresión lineal	3,35	1,46	1,31	7,63	1,55%
	Red neuronal	3,18	1,27	1,17	6,79	
	Modelo Hargreaves			1,43	8,34	
Validación espacial	Regresión lineal	3,48	1,35	1,08	6,21	1,37%
	Red neuronal	3,46	1,25	1,00	5,75	
	Modelo Hargreaves			1,23	7,12	
Validación temporal	Regresión lineal	3,20	1,89	1,69	9,88	1,39%
	Red neuronal	3,11	1,56	1,42	8,29	
	Modelo Hargreaves			1,66	9,68	

⁽¹⁾ Diferencia del Error Relativo (ER) estimado al aplicar el modelo de Hargreaves y la RNA. RMSE, Raíz del Error Cuadrático Medio; ER, Error relativo; T_{max} , temperatura máxima; T_{min} , temperatura mínima; R_a , radiación solar extraterrestre.

Y = 4.520.000 m en el oeste, e Y = 4.420.000 m en el este, la R_{sg} promedio anual no supera los 6.000 MJ m⁻² año⁻¹, con localizaciones donde los valores superan ligeramente los 5.600 MJ m⁻² año⁻¹, y que corresponden con zonas serranas del extremo más Nordeste (proximidades de Sierra Menera). Como característica, reseñar que el área citada se localiza en su totalidad en una altitud superior a los 1.200 msnm. Entre ésta, y hasta el área delimitada por las coordenadas Y = 4.450.000 m en el oeste de la región e Y = 4.300.000 m en el este de la misma, la R_{sg} oscila entre los 16,5 y 17 MJ m⁻² año⁻¹. Estas zonas corresponden en la mitad occidental de la región con las denominadas comarcas de La Sagra y Monte de los Yébenes (provincia de Toledo)

y, en la mitad oriental (de norte a sur) con: Campiña, Alcarria baja y Alcarria de Guadaluajara, Serranía Conquense, Mancha Alta en Cuenca, y Manchuela. Existe una excepción, en el área delimitada por las coordenadas X = 580.000 m hasta X = 630.000 m en latitud, e Y = 4.350.000 m hasta Y = 4.400.000 m en longitud, donde se superan los 17 MJ m⁻² día⁻¹. En el resto de la región, los valores son superiores situándose en valores próximos a 6.250 MJ m⁻² en un año medio (17,25 MJ m⁻² día⁻¹).

Valores de R_{sg} por encima de los 17,5 MJ m⁻² día⁻¹ se pueden observar en la región en localizaciones puntualizadas del extremo Sur y Sureste (zona límite de las denominadas comarcas de La Sierra del Segura y de Hellín, res-

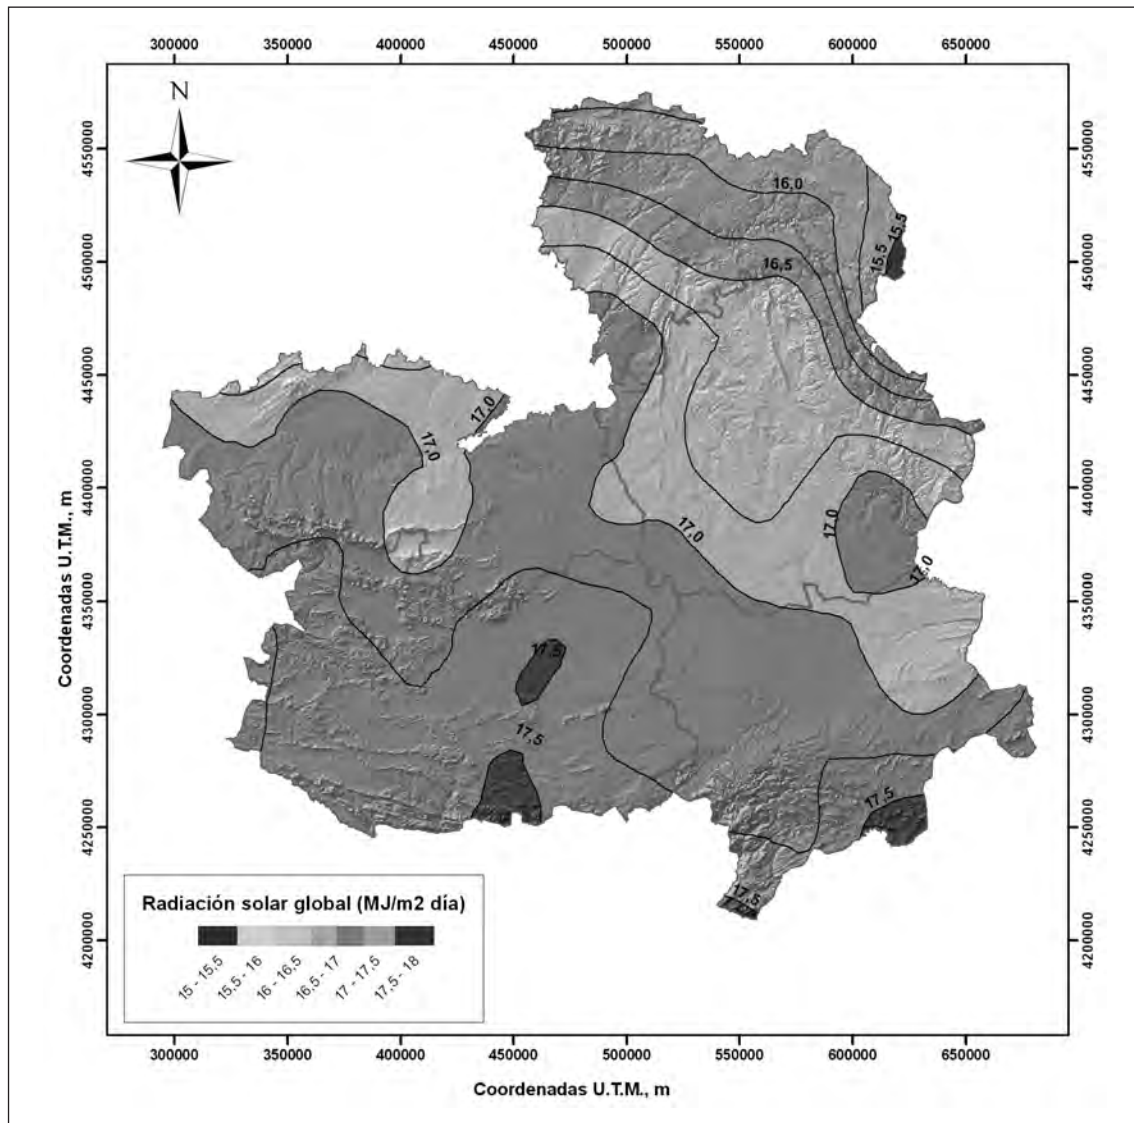


Figura 5. Mapa de isolíneas de la radiación solar global promedio anual en Castilla-La Mancha.
 Figure 5. Isoline map of the annual average global solar radiation in Castilla-La Mancha.

pectivamente). También entorno a las áreas localizadas en las coordenadas (450.000, 4.250.000) (Sierra de San Andrés) y algo más al norte (450.000, 4.320.000) se detectan valores promedios anuales que pueden superar los 6.400 MJ m^{-2} .

Los mapas nacional de radiación, elaborado mediante el tratamiento de imágenes del satélite Meteosat (Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas; CIEMAT, 2001), y regional (Agencia de la Energía de Castilla-La Mancha; AGECAM,

Tabla 6. Parámetros de los semivariogramas ajustados y estadísticos de la validación cruzada de la radiación solar global promedio anual y estacional
 Table 6. Parameters of the adjusted semivariograms and cross-validation statistics of the annual and seasonal global solar radiation

	Anual	Primavera	Verano	Otoño	*Invierno
Tipo de modelo de semivariograma	Esférico	Esférico	Esférico	Esférico	Esférico
Nugget ($\text{MJ m}^{-2} \text{ día}^{-1})^2$	0,22	0,62	0,27	0,16	0,00
Varianza estructural ($\text{MJ m}^{-2} \text{ día}^{-1})^2$	0,10	0,35	0,14	0,12	0,00
Sill ($\text{MJ m}^{-2} \text{ día}^{-1})^2$	0,32	0,97	0,41	0,28	0,00
Alcance muestral en superficie (km)	Máximo Mínimo	63,30 69,75	69,75 64,89	64,89 159,28	159,28 69,12
ME ($\text{MJ m}^{-2} \text{ día}^{-1}$)	-0,015	-0,022	-0,023	0,002	-0,007
RMSE ($\text{MJ m}^{-2} \text{ día}^{-1}$)	0,549	0,957	0,592	0,465	0,411
Media del Error estándar ($\text{MJ m}^{-2} \text{ día}^{-1}$)	0,535	0,920	0,607	0,456	0,384
ME estandarizada	-0,026	-0,022	-0,035	0,006	-0,018
RMSE estandarizado	1,027	1,038	0,981	1,020	1,063
Tipo de tendencia	2° orden	2° orden	2° orden	–	2° orden
Tipo kriging	Simple	Simple	Simple	Simple	Simple

(*) Representa los valores tras realizar la transformación logarítmica de los datos. ME, Media de los errores observados; RMSE, Raíz del Error Cuadrático Medio.

2007) ofrecen tendencias similares en cuanto a la distribución de la R_{sg} en C-LM. En las zonas con menor R_{sg} , los valores se cifran, dependiendo del mapa consultado, entre los 14,4 y los 15,5 $\text{MJ m}^{-2} \text{ día}^{-1}$, y los más elevados, se aproximan a los 16,5 y los 17,3 MJ m^{-2} en función del mapa utilizado. Aún así, en los mapas citados es difícil precisar en los valores representados debido a la metodología empleada en su representación y resolución espacial.

A continuación, se exponen los mapas de interpolación de la R_{sg} media diaria sobre una superficie horizontal (Fig. 6) correspondientes a los períodos trimensuales de primavera, verano, otoño e invierno, basados en los modelos definidos en la Tabla 6.

Las diferencias de R_{sg} promedio diaria para las distintas estaciones a lo largo del año son elevadas. La mayor homogeneidad en los datos se observa en otoño e invierno, cuando los valores son menores, con mínimos en las cotas más elevadas del norte y máximos en la mitad sur. Las diferencias se acentúan durante la primavera y verano. En el verano, la distribución de la R_{sg} en el área delimitada por la región de CL-M es muy similar a la anual, con valores en la zona de menor radiación que oscilan entre los 25 $\text{MJ m}^{-2} \text{ día}^{-1}$ (Norte y nordeste de esta área), y los 26 $\text{MJ m}^{-2} \text{ día}^{-1}$ (sur de esta área), lo que representa aproximadamente el 60% de la R_{sg} total anual acumulada. Se observa un aumento

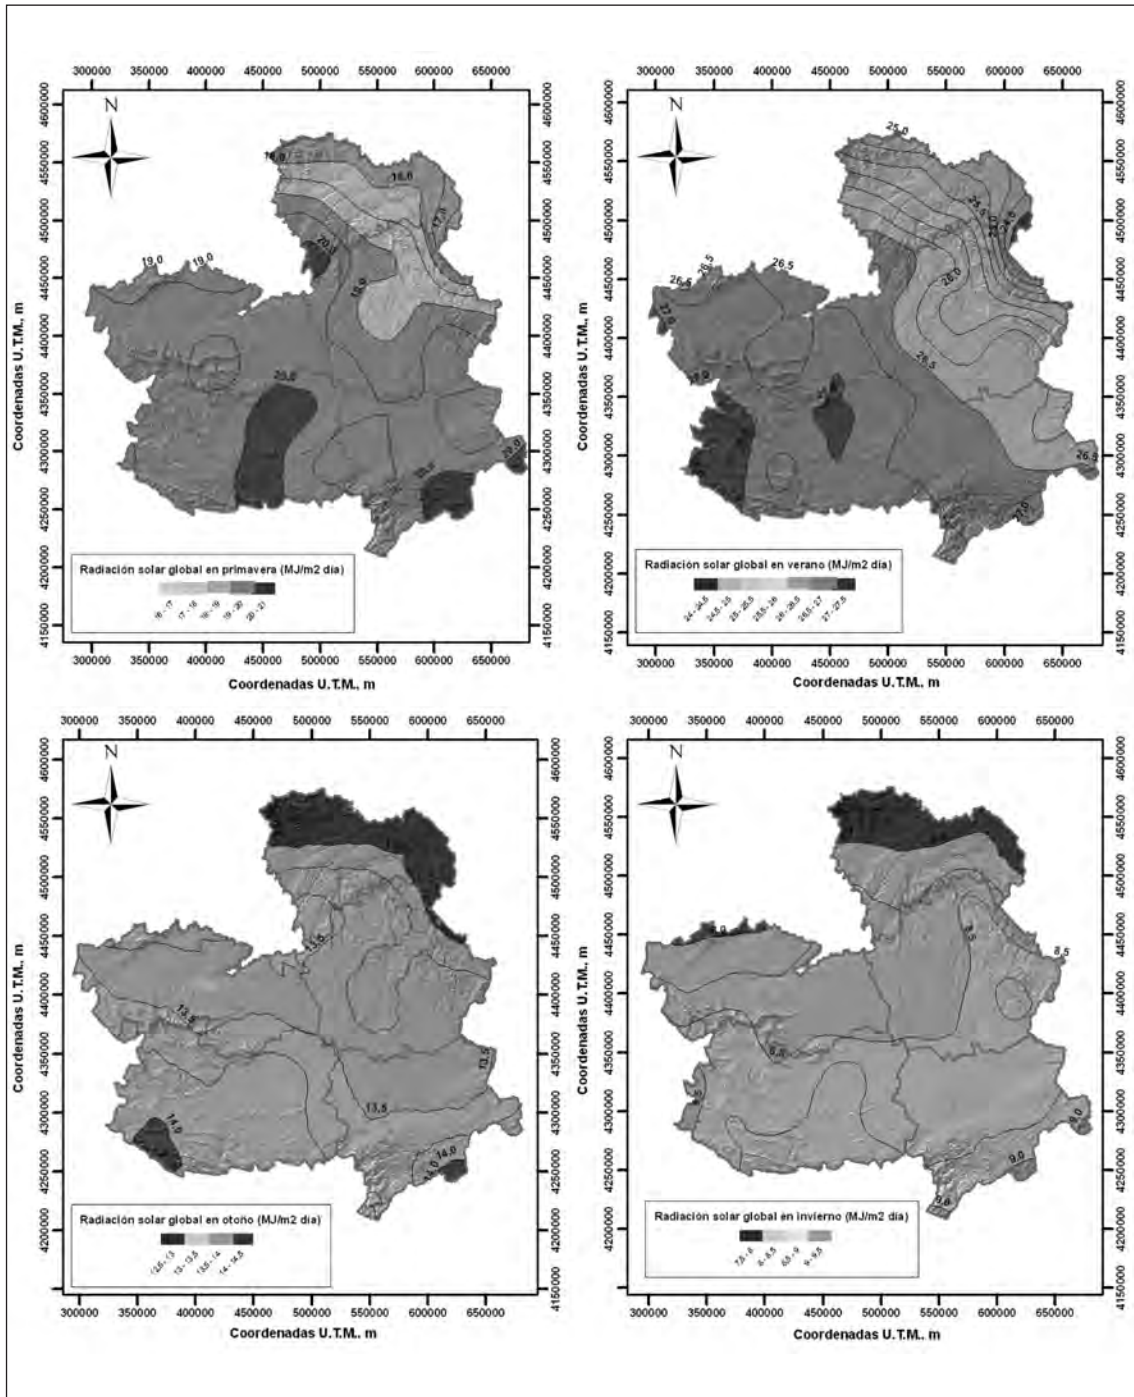


Figura 6. Mapas de isóneas de la radiación solar global promedio estacional en Castilla-La Mancha.
 Figure 6. Isoline maps of global solar radiation seasonal average in Castilla-La Mancha.

gradual de la R_{sg} en dirección Sur y Suroeste hasta llegar a los $26,5 \text{ MJ m}^{-2} \text{ día}^{-1}$. El área englobada entre estos valores coincide con la delimitada para los promedios anuales entre $16,5$ y $17 \text{ MJ m}^{-2} \text{ día}^{-1}$, excluyendo las comarcas de la provincia de Toledo citadas para el promedio anual (Fig. 5). En resto de la región los valores llegan hasta $27 \text{ MJ m}^{-2} \text{ día}^{-1}$ como máximo, salvo en localizaciones puntuales donde pueden superarse levemente.

De los mapas de interpolación de R_{sg} media diaria correspondientes a los períodos men-

suales se han seleccionado por su contraste los de Enero y Julio (Fig. 7). Durante el mes de enero, se puede observar una gran homogeneidad en la distribución de la R_{sg} , con una marcada regionalización Norte-Sur. Los valores estimados oscilan para cualquier punto de la región entre los $7 \text{ MJ m}^{-2} \text{ día}^{-1}$, y los $8,5 \text{ MJ m}^{-2} \text{ día}^{-1}$. Durante el mes de Julio los mínimos valores se estiman en el extremo Nordeste (alrededor de $26 \text{ MJ m}^{-2} \text{ día}^{-1}$). Los máximos, en la mitad oeste y en el extremo Sudeste, oscilan entre los 28 y $28,5 \text{ MJ m}^{-2} \text{ día}^{-1}$.

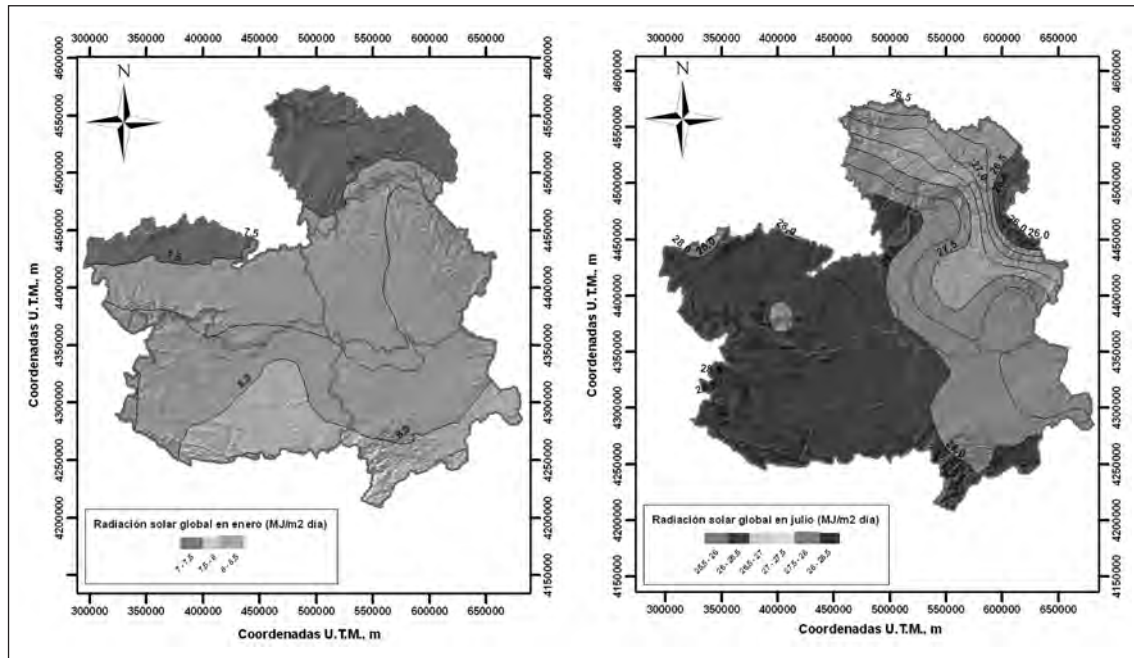


Figura 7. Mapas de isolíneas de radiación solar global promedio mensual en Castilla-La Mancha.
 Figure 7. Isoline maps of monthly average global solar radiation in Castilla-La Mancha.

Conclusiones

El uso de RNAs es de utilidad para la generación de parámetros climáticos a partir de otros registros de los que se disponga información, mostrando en este caso una buena

adaptabilidad y resultados adecuados en el proceso de estimación de la R_{sg} en concisiones de limitación de registros.

La estructura de RNA para la estimación de la R_{sg} a partir de datos de T_{max} , T_{min} y R_a , se

ha seleccionado mediante el uso de gráficos de superficie de respuesta, y queda definida por 12 nudos y 210 iteraciones.

Teniendo presente lo expuesto, para este modelo de RNA, se ha seleccionado la estructura definida por 12 nudos y 210 iteraciones.

En C-LM, a partir de registros promedios de temperaturas mensuales, la R_{sg} fue estimada aplicando modelos basados en RNAs con un ER promedio esperado de entre 5,8% y 8,3%, frente al rango del 7,1% y 9,7% que muestra el modelo de Hargreaves recomendado por FAO.

La aplicación de una de las técnicas de geostatística (KS), disponiendo de una serie de datos de R_{sg} histórica representativa, ha permitido la elaboración de una cartografía continua y georreferenciada que caracteriza la R_{sg} en C-LM. Los valores promedios de R_{sg} anual acumulada se estiman en rangos de entre los 6.400 MJ m⁻² y 6.200 MJ m⁻², 6.200 MJ m⁻² y 6.000 MJ m⁻², y, 6.000 MJ m⁻² y 5.800 MJ m⁻², para aproximadamente el 55%, 25% y 15% de la región respectivamente.

Agradecimientos

A la CICYT por la financiación del proyecto nacional (AGL2007-66716-C03-03), y a la Consejería de Educación de la JCCM por la financiación del proyecto (PCI08-0117) en los que se ha enmarcado este trabajo.

Abreviaturas

C-LM: Castilla- La Mancha

ER: Error relativo

ETo: evapotranspiración de referencia

IS: Índice de Similitud

KS: kriging simple

P: precipitación

RL: Regresión lineal

RNA: Red neuronal artificial

R_a : Radiación solar extraterrestre

R_s : Radiación solar

R_{sg} : Radiación solar global

RMSE: Raíz cuadrada del error cuadrático medio "Root Mean Square Error"

R^2 : Coeficiente de determinación

SIAR: Servicio de Información Agroclimática para el Regadío

SIG: Sistema de Información Geográfica

T_{max} : Temperatura máxima

T_{med} : Temperatura media

T_{min} : Temperatura mínima

Referencias bibliográficas

AGECAM, 2007. [En línea]. Mapa de radiación solar. Agencia de Gestión de la Energía de Castilla-La Mancha, Albacete, España. <http://www.agecam.es> [Consulta: marzo 2009].

Aguar R, Collares M, 1992. A time dependent, autorregressive, gaussian model for generating synthetic hourly radiation. *Sol. Energy* 49: 167-174.

Aguilar E, Auer I, Brunet M, Peterson TC, Wieringa J, 2003. Guidelines on climate metadata and homogenization. WMO-TD No. 1186, World Meteorological Organization, Geneva, Switzerland.

Allen RG, Pereira LS, Raes D, Smith M, 1998. Crop Evapotranspiration. Guidelines for Computing Crop water Requirements. FAO Irrigation and Drainage paper No. 56, Food and Agriculture Organization of the United Nations (FAO), Rome, Italy.

- Allison PD, 2000. Multiple imputation for missing data: A cautionary tale. *Sociol. Methods. Res.* 28: 301-309.
- Alsamamra H, Ruiz-Arias JA, Pozo D, Tovar J, 2009. A comparative study of ordinary and residual kriging techniques for mapping global solar radiation over southern Spain. *Agric. For. Meteorol.* 149: 1343-1357.
- Ávila OJ, Abril JC, Lesino G, 2000. Radiación y temperatura diarias: Un modelo de correlación estructural. *Avances en Energías Renovables y Medio Ambiente* 2: 31-37.
- Berengena J, Gavilán P, 2005. Reference evapotranspiration estimation in a highly advective semiarid environment. *J. Irrig. Drain. Eng. ASCE* 131 (2): 147-163.
- Castellví F, Elías F, 2001. Tratamiento estadístico de datos. En: Elías, F.; Castellví, F. (coords.). *Agrometeorología* (2ª Ed.) (447-486). Mundi-Prensa, Madrid, España.
- CIEMAT, 2001. [En línea]. Mapa de España de Radiación Solar. Media diaria anual sobre superficie horizontal. Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas, Ministerio de Ciencia e Innovación, Madrid, España. <http://www.ciemat.es> [Consulta: enero 2010].
- Coll S, Guijarro M, 2007. *Estadística Aplicada a la Historia y a las Ciencias Sociales*. Pirámide, Madrid, España.
- CREA, 2009. [En línea]. Centro Regional de Estudios del Agua, Servicio Integral de Asesoramiento al Regante, Albacete, España. <http://crea.uclm.es/siar/> [Consulta: marzo 2009].
- Cristóbal J, Jiménez-Muñoz JC, Sobrino JA, Ninyerola M, Pons X, 2009. Improvements in land surface temperature retrieval from the landsat series thermal band using water vapour and air temperature. *J. Geophys. Res.* (in press).
- Dai X, Shi H, Li Y, Ouyang Z, Huo Z, 2008. Artificial neural network models for estimating Regional reference evapotranspiration based on climate factors. *Hydrol. Process.* 23: 442-450.
- de la Casa A, Ovando G, Rodríguez A, 2003. Estimación de la radiación solar global en la provincia de Córdoba, Argentina, y su empleo en un modelo de rendimiento potencial de papa. *Revista de Investigaciones Agropecuarias* 32: 45-62.
- de León A, Arriba A, de la Plaza MC, 1974. *Caracterización Agroclimática de España*. Ministerio de Agricultura, Pesca y Alimentación, Secretaría General Técnica, Madrid, España.
- DMAGA, 2008. [En línea]. Atlas climático de Aragón. Departamento de Medio Ambiente del Gobierno de Aragón, Zaragoza, España. <http://portal.aragon.es> [Consulta: Julio 2009].
- Dorvlo ASS, Jervase JA, Al-Lawati A, 2002. Solar radiation estimation using artificial neural networks. *Applied Energy* 71 (4): 307-319.
- Elías F, Ruiz-Beltrán L, 1981. *Estudio Agroclimático de la Región de Castilla-La Mancha*. Departamento de Agricultura de la Junta de Comunidades de Castilla-La Mancha, Toledo, España.
- Font I, 2000. *Climatología de España y Portugal* (2ª Ed.). Universidad de Salamanca, Salamanca, España.
- Gavilán P, 2010. Modelos de estimación de la radiación solar diaria a partir de medidas de la temperatura. III Jornadas de gestores y usuarios de redes de estaciones agrometeorológicas. Mérida (España), 23 y 24 de noviembre.
- Glover J, McCulloch J, 1958. The empirical relation between solar radiation and hours of bright Sunshine. *Q. J. R. Meteorol. Soc.* 84: 172-175.
- Goodin DG, Hutchinson JMS, Vanderlip RL, Knapp MC, 1999. Estimating solar irradiance for crop modeling using daily air temperature data. *Agron.J.* 91: 845-851.
- Gómez-Tagle ChA, 2003. Sol_Rad Pt, Programa para cálculo de radiación solar en superficies simples. Facultad de Biología de la Universidad Michoacana de San Nicolás de Hidalgo, Morelia, México.
- Hargreaves GH, 1994. Simplified coefficients for estimating monthly solar radiation in North America and Europe. *Dept. Paper. Dept. Biol. And Irrig. Eng.* Utah State Univ, Logan, Utah.
- Hargreaves GH, Samani ZA, 1985. Reference crop evapotranspiration from temperature. *Appl. Eng. Agric.* 1 (2): 96-99.

- Harold J, 2004. Algoritmos de Estimación e interpolación de parámetros geofísicos. Tesis Doctoral. Facultad de Artes y Ciencias, Universidad de Puerto Rico Recinto de Mayagüez, Mayagüez, Puerto Rico.
- Hocking RR, 1976. The analysis and selection of variables in linear regression, *Biometrics* 32: 1-49.
- Hurtado E, Sobrino JA, 2001. Daily net radiation estimated from air temperature and NOAA-AVHRR data: a case study for the Iberian Peninsula. *Int. J. Remote Sens.* 8 (20): 1521-33.
- Isaaks EH, Srivastava RM, 1989. *Applied Geostatistics*. Oxford University Press, Oxford, United Kingdom.
- Jiang Y, 2008. Prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models. *Energy Policy*. 36: 3833-3837.
- Kasten F, Golchert HJ, Dogniaux R, Lemoine M, 1996. *European Solar Radiation Atlas*. Springer-Verlag, Berlin, Alemania.
- Krishnaiah T, Srinivasa Rao S, Madhumurthy K, Reddy KS, 2007. Neural Network Approach for Modelling Global Solar Radiation. *Journal of Applied Sciences Research*, 3(10): 1105-1111.
- Kumar M, Bandyopadhyay A, Raghuwanshi NS, Singh R, 2008. Comparative study of conventional and artificial neural network-based ETO estimation models. *Irrig. Sci.* 26: 531-545.
- Kumar M, Raghuwanshi NS, Singh R, Wallender WW, Pruitt WO, 2002. Estimating evapotranspiration using artificial neural network. *J. Irrig. Drainage Eng-ASCE* 128: 224-233.
- Kumar M, Raghuwanshi NS, Singh R, 2010. Artificial neural networks approach in evapotranspiration modelling: a review. *Irrig Sci* DOI: 10.1007/s00271-010-0230-8.
- Lawrence S, Giles CL, Tsoi A, 1997. Lessons in neural network training: Overfitting may be harder than expected. 14th National Conference on Artificial Intelligence July 27-31, AAAI-97, AAAI Press, Menlo Park, California, CA, USA, pp. 540-545.
- Luque T, 2000. *Técnicas de Análisis de Datos en Investigación de Mercados*. Pirámide, Madrid, España. [In Spanish].
- Martínez-Cob, A, Faci, JM, Quilez D, Berenguer JM, 1994. Aplicación de la geoestadística en la investigación agraria: Resultados prácticos en la agricultura aragonesa. *Riegos y Drenajes* 10: 23-27.
- Martínez-Romero A, Ortega JF, de-Juan JA, Tardjuelo JM, Moreno MA, 2010. Development of relative humidity models by using optimized neural network structures. *Span. J. Agric. Res.* 2010 8(S2), S162-S171.
- Martínez-Romero A, 2010. Parámetros agroclimáticos y su distribución espacial en Castilla-La Mancha. Tesis Doctoral. Escuela Técnica Superior de Ingenieros Agrónomos de Albacete, Albacete, España, 514 pp.
- MMA, 2008. [En línea]. Información estadística y ambiental. Ministerio de Medio ambiente. <http://www.mma.es> [Consulta: mayo 2009].
- Nabney IT, 2001. *Netlab. Algorithms for Pattern Recognition (4ª Ed.)*. Springer Verlag, London, United Kingdom.
- Olea RA, 1999. *Geostatistics for Engineers and Earth Scientists*. Kluwer Academic Publishers, Norwell, MA. USA.
- Pelayo JL, 2004. [En línea]. El Heliógrafo de Campbell-Stokes. *Revista del Aficionado a la Meteorología*. No. 26-diciembre. <http://ram.meteor-red.com> [Consulta: agosto 2008].
- Pons X, 1996. Estimación de la Radiación Solar a partir de modelos digitales de elevaciones. Propuesta metodológica. En: J. Juaristi; I. Moro; (eds.). *Modelos y Sistemas de Información en Geografía*. VII Coloquio de Geografía Cuantitativa, Sistemas de Información Geográfica y Teledetección. Grupo de Métodos Cuantitativos, SIG y Teledetección de la Asociación de Geógrafos Españoles (AGE), Vitoria-Gasteiz, España.
- Rees MJ, 1968. Polarization and Spectrum of the Primeval Radiation in an Anisotropic Universe. *Astrophys. J.* 153: L1-L5.
- Rehman S, Mohandes M, 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy* 36 (2): 571-576.
- Rehman S, Ghori SG, 2000. Spatial estimation of global solar radiation using geostatistics. *Renew. Energy* 21: 583-605.

- Rietveld MR, 1977. A new method for estimating the regression coefficients in the formula relating solar radiation to sunshine. *Agric. For. Meteorol.* 19: 243-525.
- Ritchie MD, White BC, Parker JS, Hahn LW, Moore JH, 2003. Optimization of neural network architecture programming improves detection and modelling interactions in studies of human diseases. *BMC Bioinformatics* 7: 4-28.
- Samper FJ, Carrera J, 1990. *Geoestadística: Aplicaciones a la Hidrología Subterránea*. Centro Internacional de Métodos Numéricos en Ingeniería, Barcelona, España.
- Schalkoff RJ, 1997. *Artificial Neural Networks*. McGraw Hill, New York, NY, USA.
- Shank D, 2003. *Drew point temperature prediction using artificial neural networks*. Thesis Doctoral. Artificial Intelligence Center, and the Department of Biological and Agricultural Engineering, Driftmier Engineering Center, University of Georgia, Athens, GA, USA.
- Sidrach CM, Mora L, Ramírez L, Marchante M, Navarro A, 2002. Generación de años tipo de radiación global y temperatura para su uso en el dimensionado de sistemas fotovoltaicos. *Forum International sur les energies Renouvelables*. May 19-21, Tetouan, Morocco.
- Trajkovic S, 2007. Hargreaves vs. Penman-Monteith under Humid Condition. *J. Irrig. Drainage Eng.* Eng-ASCE 133, 47-52.
- von Storch H, Zwiers FW, 1999. *Statistical Analysis in Climate Research*. Cambridge University Press, Cambridge, United Kingdom.
- Webster R, Oliver MA, 2001. *Geostatistics for Environmental Scientists*. John Wiley & Sons, Chichester, United Kingdom.
- Willmott CJ, 1982. Some comments on the evaluation of model performance. *Bulletin American Meteorological Society (AMS)* 63: 1309-1313.
- Xu S, Ling C, 2008. A novel approach for determining the optimal number of hidden layer neurons for FNN's and its application in data mining. *Proc V Intl Conference on Information Technology and Applications*. Cairns, QLD, Australia, Jun 23-26. pp. 683-686.
- Zanetti SS, Sousa EF, Oliveira VPS, Almeida FT, Bernardo S, 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. *J. Irrig. Drainage Eng-ASCE* 33, 83-89.

(Aceptado para publicación el 8 de junio de 2012)