

Modelado de la Radiación Solar Global Horaria Sobre Superficie Inclinada Mediante Redes Neuronales Artificiales

J.L. Bosch ⁽¹⁾, G. López-Rodríguez ⁽²⁾, F.J. Batlles ⁽¹⁾, J. Tovar-Pescador ⁽³⁾

⁽¹⁾ Dpto. Física Aplicada, Universidad de Almería. e-mail: jlbosch@ual.es, fbatlles@ual.es

⁽²⁾ Dpto. Ingeniería Eléctrica y Térmica, E.P.S. La Rábida, Universidad de Huelva. e-mail: gabriel.lopez@die.uhu.es

⁽³⁾ Dpto. Física Aplicada, Universidad de Jaen. e-mail: jtovar@ujaen.es

Resumen

La disponibilidad de datos de radiación solar sobre superficies inclinadas resulta de gran importancia cuando se pretende diseñar sistemas solares tanto pasivos como activos. Sin embargo, dichos datos no se suelen encontrar disponibles en la localización a estudiar; e incluso cuando se encuentra presente una estación radiométrica, suele ser la radiación sobre superficie horizontal la única medida. Las Redes Neuronales Artificiales representan una poderosa herramienta, que puede ser utilizada como alternativa en el modelado de la radiación. En este trabajo, se utiliza un Perceptrón Multicapa (MLP, *Multi-Layer Perceptron*) para estimar la radiación solar global horaria en una superficie inclinada y, en base a un estudio anterior, se discute la aplicación del método bayesiano de Determinación Automática de la Relevancia (ARD, *Automatic Relevance Determination*) para el estudio de las variables implicadas. Para llevar a cabo este modelo se ha utilizado un año de datos meteorológicos y de radiación sobre superficie horizontal e inclinada de una estación radiométrica ubicada en Valladolid. Se ha estudiado la importancia relativa de las diversas variables radiométricas y meteorológicas, derivándose de dicho estudio la selección de las variables de entrada al MLP. Se han probado y comparado los resultados de distintas topologías del perceptrón modificando el número de neuronas en la capa de entrada y en la capa oculta.

El modelo de red neuronal finalmente desarrollado presenta unos resultados satisfactorios. Además, en este trabajo se ha comprobado que el método ARD permite, de manera sencilla, determinar las variables más relevantes implicadas en un proceso en el que se desconoce a priori la importancia relativa de un grupo de variables del que se dispone de información.

Introducción

La mayoría de los sistemas solares activos o pasivos, como paneles fotovoltaicos o colectores, plantas de desalación solar o secadores solares, basan su diseño en el conocimiento de datos de calidad referidos a la cantidad de radiación incidente sobre superficies inclinadas. Para el diseño de edificios bioclimáticos que aprovechen eficientemente dicha energía solar pasiva o activa, los arquitectos e ingenieros necesitan conocer la distribución de la radiación a lo largo del año sobre diferentes superficies inclinadas para construir edificios cuyo interior ofrezca un clima agradable durante todo el año y que minimicen la energía utilizada en iluminación y calefacción o refrigeración.

Un método comúnmente empleado para transformar la energía solar en electricidad se basa en el uso de células fotovoltaicas. La potencia suministrada por dichas células depende, entre otros factores, de los niveles de insolación así como del ángulo de incidencia de la radiación solar. En el mismo sentido, la inclinación de un colector solar debe ser estudiada para obtener la mejor productividad en función de la localización.

Generalmente, el diseño de sistemas de energía solar requiere datos de radiación solar medidos en la zona estudiada o en un punto suficientemente próximo para poder aplicar técnicas de interpolación. Desafortunadamente, se dispone de relativamente pocas estaciones radiométricas que midan las componentes de la radiación solar en superficies inclinadas, lo que dificulta la disponibilidad de datos en el sitio de interés.

Por esta razón, la radiación solar sobre superficie inclinada debe ser estimada a partir de otras variables comúnmente medidas. Con este propósito, varios autores han publicado en años anteriores diversos modelos basados en las componentes global y difusa de la radiación solar

sobre superficie horizontal, como el modelo Isotrópico de Liu y Jordan, el modelo de Hay, o el modelo de Perez.

El modelo Isotrópico [Liu y Jordan, 1963] ofrece el método más simple y calcula la irradiación horaria sobre la superficie inclinada a partir de la irradiación horaria sobre superficie horizontal y el ángulo de inclinación, sin mayor consideración acerca de la anisotropía del cielo. El modelo de Hay y McKay [1988] utiliza valores de radiación sobre superficie horizontal y discrimina en el cielo la zona circunsolar, añadiendo variables como el ángulo cenital y el ángulo de incidencia sobre la superficie inclinada. La aproximación de Perez et al. [1987] es algo más compleja, estudiando el área del horizonte por separado e introduciendo el valor de la masa óptica como variable de entrada al modelo.

A estos modelos se han unido otros en los últimos años, ofreciendo un amplio conjunto de configuraciones con diferentes variables de entrada, bases temporales y localizaciones geográficas.

Las redes neuronales artificiales (RNA), ofrecen un nuevo método que puede ser utilizado como una buena alternativa a los métodos estadísticos tradicionales. Las RNA se están utilizando en diversas aplicaciones como sistemas de control, robótica, medicina, reconocimiento de patrones, análisis de información y muchas otras, y han mostrado ser un camino alternativo para enfrentarse a problemas complejos. Ya que son altamente no lineales y no requieren suposiciones de partida acerca de la función que relaciona las distintas variables estudiadas, se han convertido en una útil herramienta dentro de las ciencias relacionadas con la radiación solar. Específicamente, las redes neuronales han sido utilizadas en el campo de las energías renovables en diversas aplicaciones, y han demostrado ser una alternativa viable para el modelado de la radiación solar [López et al. 2001; Reddy y Ranjan, 2003].

En este trabajo se introducen y prueban una combinación de técnicas basadas en RNA para la estimación de la radiación solar global horaria sobre una superficie inclinada. El método de determinación automática de la relevancia estudiado, se fundamenta en la unión de la estadística Bayesiana y las redes neuronales artificiales, que también ha sido utilizado en el campo de la radiación solar [López et al., 2005], proporcionando unos buenos resultados.

Nomenclatura

RNA	Red neuronal artificial
ARD	Determinación automática de la relevancia
MLP	Perceptrón multicapa
TSV	Hora solar verdadera
I_0	Irradiación Extraterrestre horaria
G	Irradiación Global horaria
D	Irradiación Difusa horaria
T	Temperatura
HR	Humedad Relativa
V_v	Velocidad del viento
V_d	Dirección del viento
P_r	Precipitación
m_r	Masa óptica relativa
m_a	Masa óptica relativa corregida de presión
k	Fracción difusa (Difusa horaria / Global horaria)
k_t	Índice de claridad (Global horaria / Extraterrestre horaria)
θ	Ángulo de incidencia sobre la superficie inclinada (en la mitad del intervalo horario)
α_s	Altura solar (en la mitad del intervalo horario)
β	Inclinación de la superficie
ω	Ángulo horario
ϕ	Latitud
H	Neuronas en la capa oculta
n	Ciclos de reestimación de los Hiperparámetros
s	Sesiones de entrenamiento
c	Ciclos de entrenamiento
α	Hiperparámetros
w	Pesos
a,b	Umbrales

1. Materiales y Métodos

1.1 Datos experimentales

El presente trabajo se ha realizado con un conjunto de datos recogidos en una estación radiométrica situada en el laboratorio del Centro de Investigación de la Baja Atmósfera (C.I.B.A), a 35 Km de la ciudad de Valladolid (41°49'N, 4°56'O), que se encuentra a una altitud de 840 metros sobre el nivel del mar. El terreno que rodea a la estación se encuentra libre de cultivos o edificaciones. Dicha estación, tiene instalados cuatro sensores, dos de ellos midiendo radiación sobre superficie horizontal (global y difusa) y otros dos midiendo radiación sobre superficie inclinada (global y difusa). Dicha superficie se encuentra inclinada 42° y está orientada hacia el sur. La toma de datos se realiza con una frecuencia de 10 minutos y se calcula la media aritmética para cada hora. Los piranómetros

utilizados son Kipp and Zonen modelo CM11 y los elementos de sombreado son una banda de sombra de Eppley modelo SBS y un anillo de sombra de Kipp and Zonen modelo CM-121 para los sensores de superficie horizontal e inclinada respectivamente. Además, se utilizan sensores estándar para medir la temperatura, humedad relativa, precipitación, velocidad y dirección del viento.

Para minimizar los errores debidos a la respuesta coseno de los sensores, sólo se han utilizado los valores de radiación correspondientes a altitudes solares mayores de 10°. También se ha aplicado la corrección por la banda de sombra siguiendo la recomendación del fabricante. El conjunto de datos finalmente utilizado está compuesto de $N = 2920$ horas.

Para completar la base de datos, se han introducido otros parámetros atmosféricos y geométricos derivados de los datos medidos. Dichos parámetros son: $\cos(\theta)$, α_s , m_f [Kasten y Young, 1989], m_a , I_0 , k_t , k , y w_g [Gueymard, 1994]. Donde,

$$\cos(\theta) = \sin(\phi - \beta) \sin \delta + \cos(\phi - \beta) \cos \delta \cos \omega \quad (5)$$

con $\beta = 42^\circ$.

La base de datos así obtenida se ha dividido aleatoriamente en dos conjuntos. El conjunto de entrenamiento, comprendiendo 2/3 de los datos, y el conjunto de validación compuesto por el tercio de datos restante. Para la selección de variables se ha utilizado el conjunto completo de datos.

1.2 Metodología

La unidad de procesamiento fundamental de una RNA recibe el nombre de neurona. Al igual que ocurre en el cerebro, una neurona artificial recibe datos desde diversas fuentes de información y lleva a cabo una operación, generalmente no lineal, sobre una combinación de dichas entradas. A continuación, la señal resultante se propaga a través de la red y es utilizada como entrada por las neuronas conectadas en la siguiente capa. El modo en que interconectan las neuronas entre sí se conoce como arquitectura de la red, y aquellas redes en que la señal se propaga hacia delante desde la capa de entrada a la capa de salida, se conocen como redes *feed-forward* (literalmente: alimentadas hacia delante). El Perceptrón Multi-Capa (MLP, Multi-Layer Perceptron) es una de las arquitecturas *feedforward* más comunes y ha sido ampliamente utilizado debido a su simplicidad.

En este trabajo, se ha empleado un MLP consistente en una capa de entrada, totalmente conectada a una capa oculta, estando esta a su vez

totalmente conectada a la capa de salida, como se muestra en la figura 1. Las neuronas ocultas recogen la información que proviene de cada entrada, multiplicada por un factor de peso. A continuación, realiza una suma de todas las entradas ponderadas y aplica una función sobre la suma (conocida como *función de activación* de la neurona), devolviendo un valor que se envía a la capa de salida. Antes de ser procesado, a dicho valor se le aplica un nuevo factor de peso y la neurona de la capa de salida repite el proceso anterior, sumando las distintas entradas ponderadas que recibe y aplicando una función sobre la suma. Una serie de entradas adicionales a cada neurona (denominadas umbrales), determinarán si la suma del resto de entradas a la neurona va a ser suficiente para producir la activación de la neurona (un resultado de la función de activación no nulo).




Figura 1. Perceptrón multicapa con una única salida

Los MLP que se han utilizado poseen diferentes combinaciones de variables de entrada así como distintos números de neuronas en la capa oculta, y tienen en común una sola neurona en la capa de salida. Tanto en la aplicación del método ARD como en la red finalmente entrenada, la función de activación empleada para la capa oculta es la tangente hiperbólica (\tanh) y para la capa de salida es una función lineal. La salida que proporciona la red se puede escribir entonces como:

$$y = \sum_{j=1}^H w_j^{salida} \tanh\left(\sum_{i=1}^n w_{ij}^{oculta} x_i + a_j\right) + b \quad (1)$$

Una vez definida la estructura de la red, el paso siguiente recibe el nombre de entrenamiento de la red. En este proceso, los pesos que controlan las conexiones entre las neuronas se ajustan mediante un algoritmo de entrenamiento con la finalidad de obtener el mejor ajuste posible de la información. El entrenamiento empleado requiere una división del conjunto de datos en dos subconjuntos, uno de ellos es usado para el entrenamiento de la red y el otro para comprobar la bondad del modelo y para evitar

un sobreajuste de los datos. Un ciclo de entrenamiento usual sigue el siguiente esquema:

- a) Un dato del subconjunto de entrenamiento se introduce en la red
- b) La salida proporcionada por la red se compara con la salida esperada
- c) El error obtenido se retropropaga a través de la red y los pesos existentes son modificados para minimizar dicho error

Este proceso se repite hasta que todos los datos del conjunto de entrenamiento han pasado por la red, completándose así un ciclo de entrenamiento. Y el entrenamiento se sigue ejecutando ya sea un número de ciclos determinado o bien hasta que se alcanza un criterio de parada establecido a priori. El algoritmo usado para el entrenamiento de la red que conforma el modelo final es el L-M (Levenberg-Marquardt) [17].

Este tipo de entrenamiento recibe el nombre de entrenamiento supervisado ya que se conoce a priori el valor deseado de la salida. La principal limitación del modelo es su tendencia a sobreajustar la información, es decir, un número suficientemente grande de ciclos de entrenamiento proporcionarían un ajuste muy preciso de los datos del conjunto de entrenamiento pero uno muy pobre del conjunto de validación, con la consiguiente pérdida de generalidad. Esto se soluciona estableciendo un criterio de parada que tenga en cuenta la evolución de los errores obtenidos tanto para el conjunto de validación como para el de entrenamiento. Por otra parte, el gran número de posibles entradas a la red también merma la posible generalización del modelo y restringe su uso, ya que todas esas medidas pueden no estar siempre disponibles. La RNA tiene la capacidad de poder incluir cualquier variable como entrada, y esto puede resultar un inconveniente a la hora de establecer las verdaderas relaciones entre variables.

La variable utilizada como salida de la red neuronal es aquella que se quiere obtener a partir de una combinación no lineal del resto de variables, que se usan como entrada a la red. Esto puede convertirse en un problema cuando se dispone de multitud de variables de entrada, y su posible influencia sobre la variable de salida no se puede descartar a priori, pudiendo dar lugar a modelos muy complejos.

Para hacer una selección de las variables que se van a introducir en la red también se ha utilizado un método basado en redes neuronales. El método Bayesiano para RNA utilizado en este trabajo, denominado Determinación Automática de la

Relevancia (ARD), limita la complejidad del modelo ayudando a seleccionar las variables más relevantes y además, no incurre en sobreajuste de los datos de entrenamiento, gracias a un factor de penalización incorporado en el modelo. ARD se basa en una interpretación probabilística de las posibles configuraciones de los pesos de la red. El método agrupa todos los pesos asociados a cada entrada y le asigna al grupo un hiperparámetro \mathbf{a}_g . Este hiperparámetro controla la distribución inicial de pesos, que se obtiene mediante una distribución Gausiana con media nula y varianza,

$$\mathbf{s}_g^2 = 1/\mathbf{a}_g \quad (2)$$

Los pesos correspondientes al grupo g ésimo son muestreados a partir de esta distribución.

También se definen tres parámetros adicionales para dar cuenta del resto de parámetros de la red (umbrales de entrada, umbrales de la capa oculta y pesos de la salida), que controlan la complejidad del modelo.




Figura 2. Los hiperparámetros controlan la distribución de los pesos

Centrándonos en los hiperparámetros asociados a cada entrada, que son los que finalmente informarán sobre la relevancia relativa de las variables, enumeramos las fases que dan lugar a su evolución, desde un valor inicial aleatorio a un valor final representativo del problema analizado.

- a) Los pesos asociados a cada entrada se muestrean a partir de los hiperparámetros
- b) El conjunto de datos D se presenta a la red
- c) Se calculan los valores posteriores de los hiperparámetros mediante el teorema de Bayes

$$p(\bar{\mathbf{w}}|\bar{\mathbf{a}}, D) = \frac{p(D|\bar{\mathbf{w}})p(\bar{\mathbf{w}}|\bar{\mathbf{a}})}{p(D|\bar{\mathbf{a}})} \quad (3)$$

$$p(\bar{\mathbf{a}}|D) = \frac{p(D|\bar{\mathbf{a}})p(\bar{\mathbf{a}})}{p(D)} \quad (4)$$

Donde $p(D|\bar{\mathbf{w}})$ es la verosimilitud (*likelihood*) y $p(D|\bar{\mathbf{a}})$ recibe el nombre de evidencia para el vector de hiperparámetros $\bar{\mathbf{a}}$. Estas distribuciones de probabilidad se determinan mediante el procedimiento para el cálculo de la evidencia de MacKay [MacKay, 1994]. En este trabajo, el procedimiento de MacKay se lleva a cabo un número 's' de sesiones iterativas. En un primer paso, se calculan los pesos maximizando la verosimilitud por medio en un entrenamiento estándar de la RNA. El algoritmo de entrenamiento seleccionado fue el gradiente escalado conjugado (SCG, Scaled conjugated gradient) [Moller, 1993], que ejecuta 'c' ciclos de entrenamiento. En el segundo paso, los hiperparámetros son re-estimados 'n' veces para proporcionar la máxima evidencia.

Los pesos de una entrada con un alto valor de \mathbf{a}_g se aproximan a cero, de modo que la entrada correspondiente no resulta relevante para explicar la variabilidad de la variable dependiente. De este modo, el método ARD permite a la red determinar automáticamente la importancia de cada entrada, anulando el efecto en la salida de aquellas que no resultan relevantes.

La implementación de los métodos ARD junto con el algoritmo de entrenamiento del gradiente escalado-conjugado se ha llevado a cabo en código de MATLAB [Mathworks, 1999] junto con varias rutinas desarrolladas por Nabney [NCRG] y Bishop.

Una vez seleccionadas las variables, se ha realizado un estudio de las diferentes estructuras posibles de la red, mediante la prueba consecutiva de diferentes MLP variando el número de neuronas en la capa oculta desde 2 neuronas hasta 30 y comparando los resultados. De este modo, se puede seleccionar un número H que optimice la complejidad del modelo en función del error proporcionado.

Por último, la red finalmente seleccionada se ha entrenado un número determinado de veces para evitar un posible efecto de la selección aleatoria inicial de los pesos en el error final del modelo.

2. Resultados

La variable seleccionada como salida de la red estudiada es la irradiación global horaria sobre superficie inclinada G_T .

En este estudio, se ha partido del siguiente grupo de variables de entrada a la red: TSV, α_s , $\cos(\theta)$, m_a , I_o , G , D , T , HR , V_v , V_d , P_r , w_g . Que ha sido reducido mediante el método ARD anteriormente expuesto.

Para comenzar con la determinación automática de la relevancia, es preciso fijar algunos parámetros del método como son: el número de neuronas en la capa oculta (H), el número de ciclos de entrenamiento (c), el número de reestimaciones de los hiperparámetros (n) y el número de sesiones de entrenamiento (s). Estos valores fueron fijados inicialmente en: $H = 5$, $s = 40$, $n = 2$, $c = 100$, debido a su bajo coste computacional y sus buenos resultados, pero fueron optimizados a posteriori como se muestra a continuación.

La primera variable fijada fue el número de neuronas en la capa oculta, H . En la figura 3 se muestra la evolución del coeficiente de ajuste R^2 de la salida proporcionada por la red frente al valor de H , que se hizo variar desde 2 a 20 neuronas. A la vista de los resultados, el valor de H seleccionado para realizar la determinación de relevancia fue de 8 neuronas en la capa oculta.




Figura 3. Evolución de R^2 frente al número de neuronas en la capa oculta




Figura 4. Evolución de R^2 frente al número de ciclos de entrenamiento.

El número de reestimaciones ‘n’ no presentó una influencia clara sobre el error de salida y se mantuvo fijo en el valor 2 para las pruebas sucesivas. El número de ciclos de entrenamiento para el algoritmo SCG, se fijó en 150 ciclos, en base a los resultados obtenidos, que se reflejan en forma gráfica en la figura 4, comprobándose que alrededor de los 150 ciclos, R^2 se volvía estable y su aumento no era significativo.

En lo que se refiere al número de sesiones de entrenamiento, debe ser suficientemente alto como para separar de forma estable las variables según su relevancia. La figura 5 muestra la evolución de los hiperparámetros asociados a cada variable (se representa su logaritmo decimal por cuestiones de escala) en función del número de sesiones ‘s’. Como se puede comprobar, 200 sesiones son suficientes para lograr una estabilidad en los valores de α .

También se puede observar en esta primera aproximación, que las variables asociadas a la precipitación lluviosa y a la velocidad y dirección del viento, presentan hiperparámetros varios órdenes de magnitud por encima del resto. Se comprueba así su poca relevancia en el cálculo de la irradiación sobre superficie inclinada. Este resultado era el que se podía esperar a priori, pero estas variables fueron incluidas para comprobar la fiabilidad del método, y también por no descartar su posible influencia de partida.

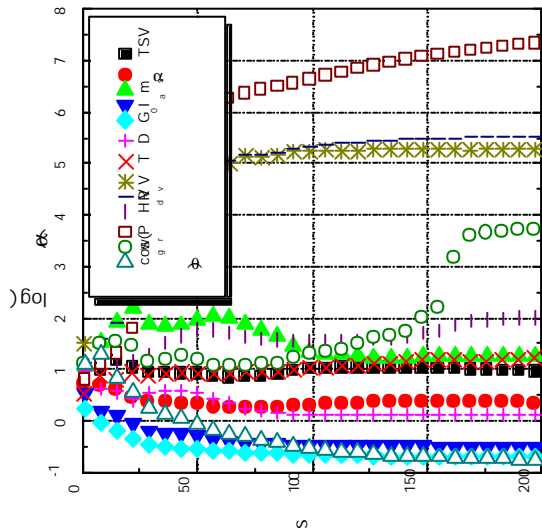


Figura 5. Evolución de los hiperparámetros

A partir de este resultado, el método ARD nos permite seleccionar las siguientes variables como más relevantes en el proceso de cálculo de la irradiación global horaria sobre la superficie inclinada: $\cos(\theta)$, I_0 , G , D y α_s .

A continuación, se volvió a ejecutar el proceso de selección sobre las 5 variables anteriores, obteniendo el resultado que se refleja en la figura 6. En esta figura se puede observar que la altura solar puede ser también eliminada y reducir el conjunto de variables a 4: $\cos(\theta)$, I_0 , G , D . En conclusión, estas son las variables que van a conformar las entradas de la red neuronal.

El siguiente paso consiste en utilizar un MLP con las variables anteriormente seleccionadas y llevar a cabo un entrenamiento que nos conduzca a los resultados finales para el modelo. El algoritmo de entrenamiento que se ha utilizado en esta fase se denomina LM (Levenberg-Marquardt). De modo análogo al seguido para fijar los parámetros del método ARD, se ha variado sucesivamente el número de neuronas de la capa oculta hasta llegar a un resultado óptimo fijado en 6 neuronas. La figura 7 muestra la conformación de la red neuronal resultante.




Figura 6. Evolución de los hiperparámetros tras la primera selección

Por último, para evitar una posible influencia de la selección aleatoria inicial de pesos sobre el modelo resultante, el entrenamiento se llevó a cabo 10 veces, y los resultados finales se presentan en la tabla 1. Donde los errores MBE y RMSE se calculan según (5) y (6) respectivamente, y se expresan finalmente como un porcentaje del valor medio de las medidas de G_s . Se han considerado los resultados de los 10 entrenamientos, y se ofrece como resultado final el valor medio de los errores obtenidos y un margen representado por la desviación típica de dichos valores.

$$MBE = \frac{\sum (X_{estimado} - X_{medido})}{N} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum (X_{estimado} - X_{medido})^2}{N}} \quad (6)$$




Figura 7. Arquitectura final del MLP

Salida	G_i
Entradas	$G, D, I_0, \cos(\theta)$
Rmse (%)	5.9 ± 0.1
Mbe (%)	0.1 ± 0.1

Tabla 1. Resultados obtenidos para la estimación de G_i mediante un perceptrón multicapa

Conclusiones

En este trabajo, se ha estudiado una técnica basada en redes neuronales artificiales para la obtención de valores horarios de radiación global sobre superficie inclinada a partir de valores de radiación sobre superficie horizontal. El método ARD se ha mostrado como un modelo sencillo para descartar las variables poco o nada relevantes, y se han obtenido buenos resultados a partir del MLP entrenado con las variables seleccionadas. El número inicial de variables se ha reducido a 4: $\cos(\theta)$, I_0 , G y D . A partir de estos valores se ha entrenado una red neuronal con dichas entradas, 6 neuronas en la capa oculta y una única salida representada por la irradiación global horaria sobre superficie inclinada G_i , obtenido un RMSE de $(5.9 \pm 0.1)\%$ y un MBE de $(0.1 \pm 0.1)\%$.

Los resultados muestran que las RNA se pueden utilizar con éxito cuando se enfrentan al modelado de la radiación sobre superficie inclinada, y que proporcionan un método alternativo para la

selección de variables, de fácil implementación y desarrollo.

Agradecimientos

Este trabajo ha sido realizado con la financiación del Ministerio de Ciencia y Tecnología a través del proyecto (ENE/2004)-07816-C03-01. Los autores desean expresar su agradecimiento al grupo de Óptica Atmosférica de la Universidad de Valladolid por la cesión de los datos utilizados en este trabajo.

Referencias

Gueymard, C. Analysis of monthly average atmospheric precipitable water and turbidity in Canada and northern United States. *Solar Energy*, 53, 57-71, 1994.

Hay, J.E., MacKay, D.C. Calculation of solar irradiance for inclined surfaces: Verification of models which use hourly and daily data. IEA Task IX Final Report, Atmospheric Environment Service, Downsview, Canada, 1988

Kasten y Young. Revised optical air mass tables and approximation formula. *Applied Optics*, 28, 4735-4738, 1989.

Liu, B., Jordan, R. The interrelationship and characteristic distributions of direct, diffuse and total solar radiation. *Solar energy*, 4, 1-19, 1960

López, G., Rubio, M.A., Martínez, M., Batlles, F.J. Estimation of hourly global photosynthetically active radiation using artificial neural networks models. *Agricultural and Forest Meteorology*, 107, 279-291, 2001

López, G., Batlles, F.J., Tovar-Pescador, J. Selection of input parameters to model direct solar irradiance by using artificial neural networks. *Energy*, 30, 1675-1684, 2005

MacKay DJC. Bayesian non-linear modelling for the energy prediction competition. *ASHRAE Transaction*; 100:1053-62, 1994.

Moller, M. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4), 525-533, 1993

Perez, R., Stewart, R., Ineichen, P., Seals, R., Menicucci, D. A new Simplified version of the Perez diffuse irradiance model for tilted surfaces. *Solar energy*, 39, 221-231, 1987

Reddy, K.S., Ranjan, M. Solar resource estimation using artificial neural networks and comparison with other correlation models. Energy conversion & management, 44, 2519-2530, 2003.

Bishop C. Neural networks for pattern recognition. London: Oxford University Press; 1995

MATLAB, The MathWorks, Inc. Natick, MA; 1999

Nabney, I. Neural Computing Research Group, NETLAB Neural Network Software. Aston University: Birmingham, UK. See also: <http://www.ncrg.aston.ac.uk/netlab/>