

RADIACIÓN SOLAR HORARIA: MODELOS DE ESTIMACIÓN A PARTIR DE VARIABLES METEOROLÓGICAS BÁSICAS

S. Sayago, M. Bocco, G. Ovando, E. Willington.
Facultad de Ciencias Agropecuarias. Universidad Nacional de Córdoba.
C.P. 5000 – Córdoba - e-mail: ssayago@agro.unc.edu.ar

RESUMEN: Estimar la radiación solar que incide en la superficie terrestre es de gran importancia, por ser ésta la principal fuente de energía renovable en la naturaleza y por ser su medición complicada y costosa. Para estimarla se han desarrollado numerosos modelos; entre éstos las redes neuronales presentan una alternativa superadora de los enfoques convencionales. El objetivo del trabajo fue desarrollar redes neuronales capaces de estimar radiación solar horaria utilizando variables meteorológicas de sencilla adquisición. Se construyeron seis modelos cuyos datos de entrada fueron: temperatura, humedad relativa, velocidad del viento y lluvia, obtenidos con una estación meteorológica automática en la provincia de Córdoba. Los resultados mostraron un buen desempeño de los modelos realizados en la estimación de la radiación solar horaria, con coeficientes de determinación entre 0,80 y 0,86, y valores de RMSE% entre 25% y 48%. Se puede concluir que las redes neuronales permiten realizar aceptables estimaciones de la radiación solar.

Palabras clave: redes neuronales, energía solar, energía renovable.

INTRODUCCIÓN

La radiación solar incidente es la principal fuente de energía renovable en la naturaleza, esencial para que se produzcan procesos biológicos, físicos y químicos, tales como fotosíntesis, evapotranspiración, crecimiento de un cultivo, etc. Debido a esto la radiación solar es un dato primordial para la construcción de modelos biofísicos y de simulación (Chen *et al.*, 2007). En particular, la predicción de datos horarios de radiación solar es muy importante en muchas aplicaciones como el dimensionamiento de sistemas de energía solar y estimaciones meteorológicas (Hocaoğlu *et al.*, 2007).

A pesar que se reconoce la importancia del registro de la radiación solar, su adquisición no es sencilla. Su medición requiere el uso de equipamientos costosos y específicos, tales como pirheliómetros y piranómetros, y no siempre es factible llevar adelante programas de monitoreo viables en países no desarrollados (Toğrul y Toğrul, 2002). La problemática de la carencia de datos suficientes de radiación en cantidad y calidad es bastante generalizada; a nivel mundial, aproximadamente sólo en una de cada 500 estaciones meteorológicas se realizan observaciones de radiación solar incidente (Raichijk *et al.*, 2005). Atendiendo a esta situación se han realizado numerosos intentos para estimarla en una amplia gama de escalas espaciales y temporales.

Entre los modelos desarrollados para estimar la radiación solar, se incluyen la ecuación de Ångström–Prescott y modificaciones de ésta, modelos lineales, polinómicos, exponenciales y logarítmicos (Menges *et al.*, 2006); también estocásticos y de redes neuronales, entre otros (Mellit *et al.*, 2005; Raichijk, 2008; Bocco *et al.*, 2010; Kaplanis y Kaplani, 2010). En particular Fadare *et al.* (2010) diseñaron diferentes redes neuronales del tipo multicapa con el algoritmo *backpropagation* para predecir radiación solar media mensual en África, utilizando como variables de entrada siete parámetros entre geográficos y meteorológicos; Leal *et al.* (2009) elaboraron modelos estadísticos para estimar radiación solar ultravioleta diaria para dos localidades de Brasil, y Spokas y Forcella (2006) desarrollaron modelos empíricos para estimar radiación solar total horaria para 18 sitios ubicados en USA y Canadá.

Los modelos basados en redes neuronales se han utilizado para superar las limitaciones de los enfoques convencionales ya que son útiles para resolver problemas complejos y no lineales. En principio, las redes neuronales pueden entrenarse para resolver problemas que son difíciles de modelar analíticamente (Haykin, 1999). Estos modelos pueden manejar gran cantidad de datos, predecir la contribución de ellos en la salida y proporcionar predicciones rápidas y adecuadas. Dentro de las redes neuronales, las del tipo perceptrón multicapa son las más utilizadas dada su capacidad de tolerar información incompleta y datos con ruido o inexactos; además los datos no deben necesariamente responder a una distribución estadística específica (Bocco *et al.*, 2010). Por otra parte, el sistema climático donde está inserta la radiación solar es complejo, está imprecisamente definido y tiene muchos parámetros físicos interrelacionados lo que hace que las redes neuronales sean aptas para la estimación de la radiación solar (Siqueira *et al.*, 2006).

Al-Alawi y Al-Hinai (1998) utilizaron redes neuronales para predecir radiación solar en áreas de Omán en las que no existe medición instrumental directa. Hocaoğlu *et al.* (2008) presentaron modelos para completar datos de radiación horaria en una estación de Turquía, utilizando varias estimaciones lineales y redes neuronales de tipo *feed-forward* con distintas variables de entrada y métodos de aprendizaje. Por otra parte, Elminir *et al.* (2007) estimaron las radiaciones solares difusas horaria y diaria incidentes en Egipto utilizando una red neuronal de tipo perceptrón. También para São Paulo, Brasil, Soares *et al.* (2004) desarrollaron una red neuronal para estimar valores horarios de radiación solar difusa en la superficie, y para Argentina, Raichijk (2008) evaluó tres modelos de redes neuronales para estimar irradiación solar en distintas localidades; Bocco *et al.* (2006) desarrollaron modelos de redes neuronales de tipo *backpropagation* para estimar radiación solar diaria para la ciudad de Córdoba. Varias arquitecturas de redes neuronales de tipo *feed-forward* fueron estudiadas por Krishnaiah *et*

al. (2007) para estimar la radiación solar global en dos localidades de India. En Argelia, Mellit *et al.* (2005) desarrollaron un modelo de red *Radial Basis Function* (RBF) que estima la radiación solar global diaria utilizando sólo datos de temperatura y heliofanía efectiva.

Entre las variables empleadas por los numerosos modelos empíricos desarrollados para calcular radiación solar, la heliofanía relativa es la más utilizada (Roldan *et al.*, 2005; Raichijk *et al.*, 2009). Sin embargo la mayoría de las estaciones meteorológicas automáticas, proveen datos de temperatura, humedad relativa, precipitación y velocidad y dirección del viento. Es por ello importante desarrollar metodologías de estimación de la radiación solar a partir de estos registros.

El objetivo de este trabajo fue desarrollar modelos de redes neuronales para estimar la radiación solar global promedio horaria a partir de los datos obtenidos directamente en estaciones automáticas y validarlos con registros de radiación solar observados. La esencia del estudio fue la construcción de modelos de predicción a partir de variables meteorológicas de sencilla adquisición.

MATERIALES Y MÉTODOS

Los datos meteorológicos utilizados para estimar la radiación solar global (irradiancia, W/m^2) fueron: temperatura ($^{\circ}C$), humedad relativa (%), velocidad de viento (km/h) y lluvia (mm) que se obtuvieron de una estación meteorológica automática marca DAVIS, Vantage PRO 2, ubicada en Cañada de Luque ($30^{\circ} 44' 53'' S$; $63^{\circ} 43' 50'' W$), provincia de Córdoba, y abarcaron el período del 13/07/07 al 01/03/11, con un intervalo de almacenamiento de datos cada 30 minutos. Esta estación provee datos de radiación solar promedio cada media hora, en un rango de 0 a $1800 W/m^2$, con una precisión $\pm 5\%$.

A los efectos de considerar valores de radiación solar en el rango horario donde se aplicarán los modelos de predicción, se utilizaron para la construcción de los mismos solamente los datos comprendidos entre las 6:00 y las 21:30 horas. Debido a la existencia de datos faltantes, en alguna de las variables, se extrajeron aquellos pertenecientes a los meses de julio y agosto de 2010 y a los días 23 y 24 de junio de 2010, quedando un total de 40.330 vectores de datos.

El análisis estadístico comenzó con el estudio de la distribución estadística a la que ajusta la radiación solar, planteando un test de Kolmogorov de bondad de ajuste ($p < 0,05$). Posteriormente se realizó el test de Shapiro-Wilks modificado por Mahibbur y Govindarajulu (1997), para todas las variables consideradas en este estudio. Este test calcula el estadístico W que permite decidir sobre la normalidad de la distribución de los datos a partir de realizar la prueba de hipótesis de distribución normal a los residuos.

Las redes neuronales representan una metodología de modelación matemática, formadas por una estructura de neuronas unidas por enlaces que transmiten información (aplicando funciones matemáticas) a otras neuronas para entregar un resultado. Las redes aprenden de la información histórica, adquiriendo así la capacidad de predecir respuestas del mismo fenómeno.

Las redes constan de una capa de entrada, una o varias capas ocultas y una capa de salida. Los datos se presentan en la capa de entrada, la/s capa/s oculta/s realizan el procesamiento de la información y la de salida incluye tantas neuronas como variables se quieran estimar. La relación entre las capas se realiza a través de la aplicación de funciones matemáticas (función escalón, tangente hiperbólica, función sigmoidea, etc.) a las sumas ponderadas por pesos de los valores de las neuronas de la capa anterior. Al llegar a la capa de salida, este proceso produce el resultado.

A través de un proceso de entrenamiento, la red en cada iteración proporciona una salida que se compara con el valor observado de la variable a estimar, obteniéndose así un error. En este proceso se determinan iterativamente los pesos de las conexiones que permiten corregir dicho error. El entrenamiento concluye cuando la red es capaz de reproducir las salidas correspondientes a los parámetros de entrada, con un error mínimo arbitrario o después de un número fijo de iteraciones (Hilera González y Martínez Hernando, 2000). En general, para acelerar el proceso de aprendizaje se aplica una tasa de aprendizaje (0,95) y una tasa de momento (0,7). El proceso final de esta metodología es la validación, que requiere siempre de un conjunto de datos independientes para los cuales se conoce el comportamiento del fenómeno y sobre los que se realiza la estimación de los errores.

Con el propósito de obtener una medida de la magnitud y dirección de la asociación de cada variable de entrada con la radiación solar, se realizó un análisis de correlación. Analizando los resultados con el software Infostat (Di Rienzo *et al.*, 2010) se observa correlación positiva entre la radiación observada y las variables temperatura ($R = 0,61$) y velocidad del viento ($R = 0,31$) y correlación negativa para humedad ($R = -0,56$), no existiendo prácticamente correlación con la precipitación ($R = -0,05$).

Se desarrollaron seis modelos de redes de tipo perceptrón multicapa (M0-M5), con propagación de la información hacia adelante; los mismos incluyeron una capa de entrada, una capa oculta (a excepción de M0 que incluyó dos) y una salida que presentaba la radiación solar promedio estimada cada 30 minutos. Se utilizó como función de relación entre las capas a la tangente hiperbólica y para finalizar la fase de entrenamiento se consideraron 3000 iteraciones o error $e < 0,001$. Se utilizó para entrenar el 70 % de los datos y la validación de los modelos se llevó a cabo con el 30% restante.

Para el modelo M1, se consideraron tres alternativas para entrenamiento y validación. Para el entrenamiento del modelo M1a se tomaron, en orden cronológico, los primeros 28.231 datos, el M1b utilizó, con el mismo orden cronológico, los últimos 28.231 datos para entrenar, mientras que para el modelo M1c se consideró la misma cantidad de datos, para entrenar, pero tomados al azar en día y horarios. Para los modelos M0-M4 los valores de entrada fueron únicamente datos provenientes de

la estación meteorológica, mientras que el modelo M5 incluyó la Radiación Solar Astronómica (RSA), variable de entrada no provista por la estación. La RSA fue calculada utilizando el programa SOLPOS - MIDC (2011) perteneciente al Laboratorio Nacional de Energía Renovable (NREL) de Estados Unidos.

Las distintas variables de entrada utilizadas en cada modelo, así como el número de neuronas de la capa oculta, se presentan en la Tabla 1.

VARIABLES DE ENTRADA	Mes	Hora	Temperatura	Humedad Relativa	Velocidad del viento	Lluvia	Radiación Solar Ast.	Neuronas Ocultas
M0	✓	✓	✓	✓	✓	✓	✗	6-4
M1	✓	✓	✓	✓	✓	✓	✗	6
M2	✓	✓	✓	✗	✗	✗	✗	3
M3	✓	✓	✓	✓	✗	✗	✗	4
M4	✓	✓	✓	✗	✓	✗	✗	4
M5	✓	✗	✓	✓	✓	✓	✓	6

Tabla 1: Diseño de los diferentes modelos de redes neuronales considerados (✓ variable incluida; ✗ variable no incluida).

Para evaluar el desempeño de los diferentes modelos de redes, se utilizó el coeficiente de determinación R^2 y la raíz del error cuadrático medio porcentual (RMSE%), definida como:

$$RMSE\% = \frac{100}{\overline{Rad}_{obs}} \sqrt{\frac{\sum_{i=1}^n (Rad_{est\ i} - Rad_{obs\ i})^2}{n}}$$

donde \overline{Rad}_{obs} es la media de la radiación observada y Rad_{est} es la radiación estimada por los modelos.

RESULTADOS Y DISCUSIÓN

A partir del test de Kolmogorov se observó que, considerando la totalidad de los datos, la radiación solar media horaria no presenta una distribución normal ($p < 0,0001$), con valores de media (318,19 W/m²), desviación estándar (317,11 W/m²) y estadístico D (0,53). Los resultados del test de Shapiro-Wilks (modificado) se muestran en la Tabla 2, donde puede apreciarse que ninguna de las variables utilizadas responde a una distribución normal ($p < 0,05$) por lo cual para estimar la radiación solar horaria el empleo de modelos como las redes neuronales es muy adecuado, ya que las mismas no requieren que los datos de entrada respondan a algún tipo de distribución estadística determinada.

Variable	Media	Desviación Standard	Estadístico W	p-valor
Temperatura	20,20 °C	8,03 °C	0,97	<0,0001
Humedad Relativa	59,32 %	21,99 %	0,94	<0,0001
Velocidad Viento	10,58 km/h	9,00 km/h	0,90	<0,0001
Lluvia	0,03 mm	0,55 mm	0,04	<0,0001
Radiación Solar	318,19 W/m ²	317,11 W/m ²	0,86	<0,0001

Tabla 2: Resultados del test de Shapiro-Wilks (modificado).

Los resultados mostraron un buen desempeño de las redes en la estimación de la radiación solar. Para el caso del modelo M0, se observaron valores de los estadísticos similares a los obtenidos por el modelo M1, con la ventaja de reducir en este último el número de conexiones y por lo tanto de operaciones computacionales a realizar en cada iteración, lo que se traduce en un acortamiento del tiempo de entrenamiento.

En la Tabla 3 pueden observarse los valores de R^2 obtenidos en la fase de validación de cada modelo.

Modelos	R^2	
M0	0,86	
M1	a	0,86
	b	0,86
	c	0,86
M2	0,80	
M3	0,84	
M4	0,80	
M5	0,86	

Tabla 3: Desempeño de los distintos modelos de redes.

El objetivo de la corrida de los modelos M1a, M1b y M1c con distintas alternativas de entrenamiento y validación (ver Materiales y Métodos), fue mostrar la no dependencia de las redes en cuanto a la elección de los datos para realizar ambas fases, lo que queda reflejado en los coeficientes de determinación obtenidos. Como expresan Moody y Antsaklis (1996) el error de entrenamiento depende en gran medida de los patrones utilizados para el mismo.

Se puede observar que M1 y M5 resultan ser los modelos que mejor estiman la radiación solar (Tabla 3), si bien el último toma como variable de entrada un dato que no es proporcionado por la estación meteorológica, lo que significa proveerse de otra fuente de información.

Los modelos M2 a M4 también presentan buenas estimaciones, siendo M2 el que considera las variables de más fácil adquisición (mes, hora y temperatura), lo cual coincide con Reddy y Ranjan (2003) quienes sostienen que los modelos de redes neuronales son versátiles y pueden utilizarse para predecir radiación solar en cualquier región que disponga de datos meteorológicos suficientes.

Los coeficientes de determinación (R^2) de todos los modelos se encuentran entre 0,80 y 0,86, valores similares a los obtenidos por Spokas y Forcella (2006) quienes utilizando modelos empíricos estimaron radiación solar horaria para un año, tomando latitud, longitud, altitud, precipitación y temperaturas máxima y mínima diarias como datos de entrada y obtuvieron un R^2 promedio de 0,85.

Los valores de R^2 de los modelos M0 a M4 pueden ser superados si se hace uso de otras variables, en particular de la heliofanía relativa, que tiene una excelente correlación con la radiación solar, entre otras. En este trabajo hemos privilegiado el uso directo de las variables que presentan únicamente las estaciones que, como la citada, son de uso frecuente en productores y estaciones experimentales. De hecho, Mellit *et al.* (2005), mediante una red RBF estimaron radiación solar diaria en Argelia usando heliofanía, temperatura y radiación solar global con un coeficiente de determinación de 0,96. Bocco *et al.* (2010) lo hicieron para Salta, a través de una red tipo perceptrón y obtuvieron un valor de $R^2 = 0,92$. Por otra parte, Elminir *et al.* (2007) estimaron radiación solar horaria, con una red de tipo perceptrón, con una capa oculta con 40 neuronas y variables de entrada radiación solar global normalizada, mes, día, hora y valores horarios de radiación global y radiación solar astronómica, obteniendo un R^2 promedio de 0,92 y Soares *et al.* (2004) presentaron un diagrama de dispersión entre radiación solar difusa observada y calculada mediante una red de tipo perceptrón con $R^2 = 0,88$, usando como variables de entrada datos horarios de radiación solar global, radiación solar difusa, emisión atmosférica de onda larga, índice de claridad, humedad relativa, ángulo de elevación solar, ángulo cenital solar, ángulo azimutal solar y presión parcial de vapor de agua.

La relación entre la radiación solar observada y la estimada, para el modelo M1, presenta una recta de ajuste de ecuación $y = 0,85x + 46,47$, con coeficiente de determinación $R^2 = 0,86$. En la Figura 1 se presenta el diagrama de dispersión correspondiente y la recta identidad, que permite distinguir en primer lugar subestimaciones para valores de radiación observada que superan los 1.000 W/m^2 . Este comportamiento ya fue observado por Bocco *et al.* (2006) y también por Li (2002).

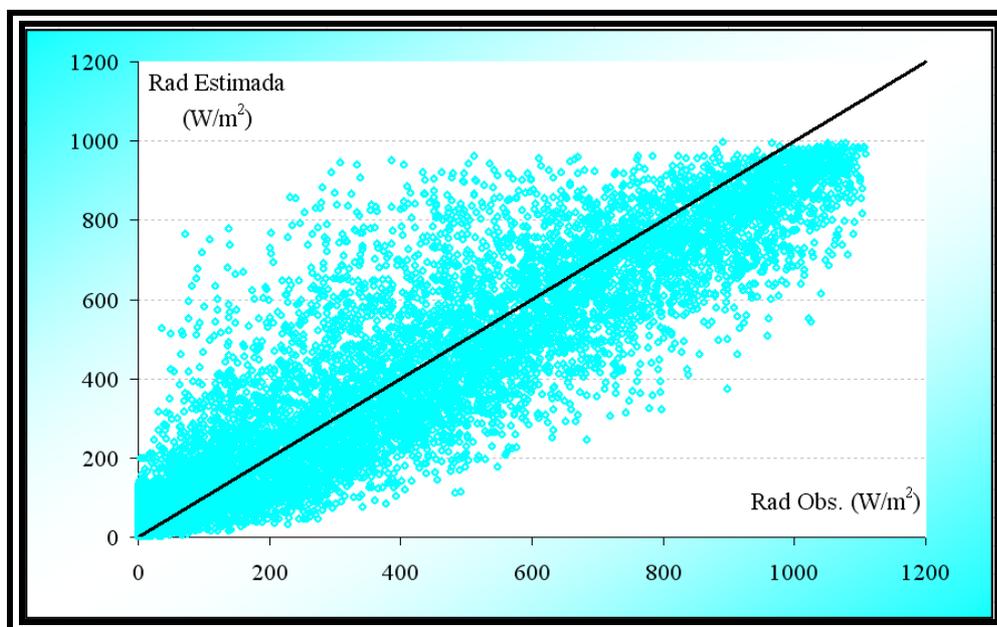


Figura 1: Diagrama de dispersión entre la radiación solar observada y la estimada obtenida por el modelo M1.

En segundo lugar, el modelo presenta un buen ajuste para valores de radiación solar entre 400 y 1.000 W/m^2 . Por último, para valores observados de radiación solar comprendidos en el rango $100 - 400 \text{ W/m}^2$, el modelo produce sobreestimaciones en algunos horarios y días, siendo éstas mayores al 35% sólo para el 4,3% de los datos.

Se realizó una comparación del RMSE% de los modelos M1 (mejor valor de R^2) y M2 (menor número de variables consideradas) para las estimaciones de radiación solar en distintas horas del día (9-10-11-13-15-16 y 17 hs) con los datos de validación considerando: i) la totalidad de los datos, ii) los datos correspondientes al mes de enero y iii) datos del mes de junio. Los resultados del RMSE%, para la totalidad de los datos, pueden observarse en la Figura 2, donde claramente el modelo M1 tiene mejor desempeño, sobre todo en los horarios de mayor intensidad de radiación solar, comportamiento debido a la mayor cantidad de variables de entrada que considera.

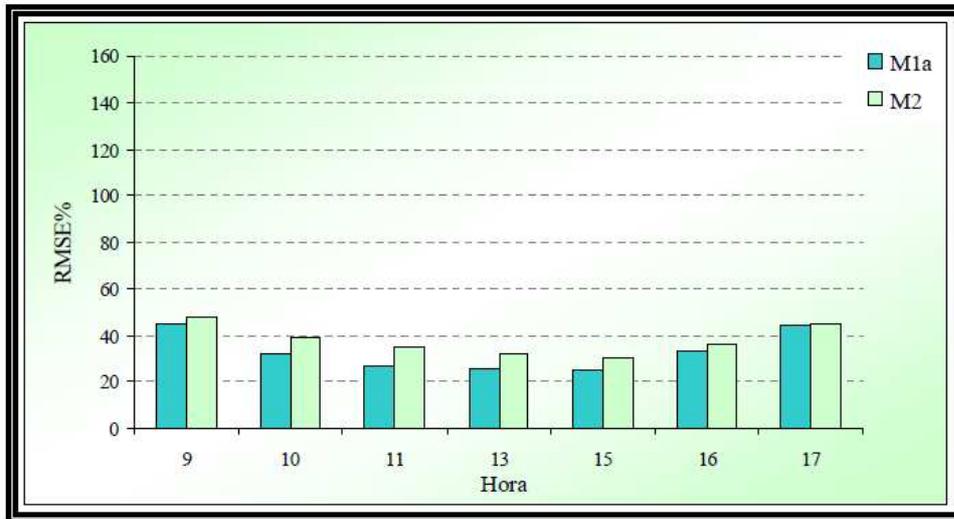


Figura 2: Comparación de la raíz del error cuadrático medio porcentual en dos modelos de redes para diferentes horarios

Para los mismos modelos se realizaron los gráficos del RMSE% considerando dos meses representativos del año uno de verano y otro de invierno. Los mismos pueden observarse en las Figuras 3a y b. Los mayores errores porcentuales se producen para el mes de junio en un horario donde los valores de radiación son bajos debido al comienzo o final del horario solar.

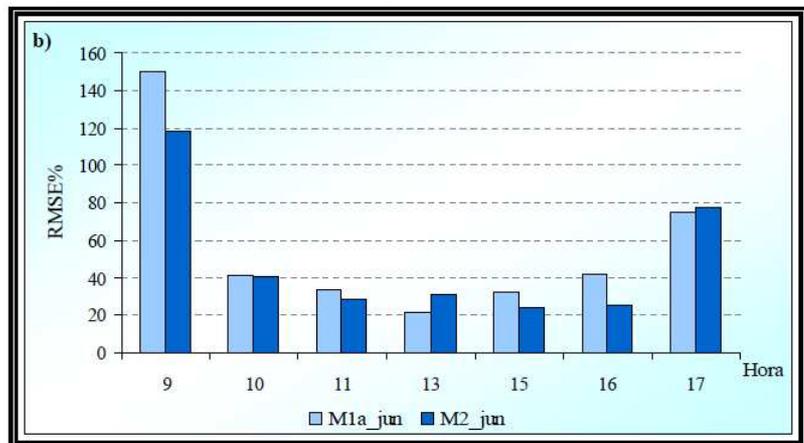
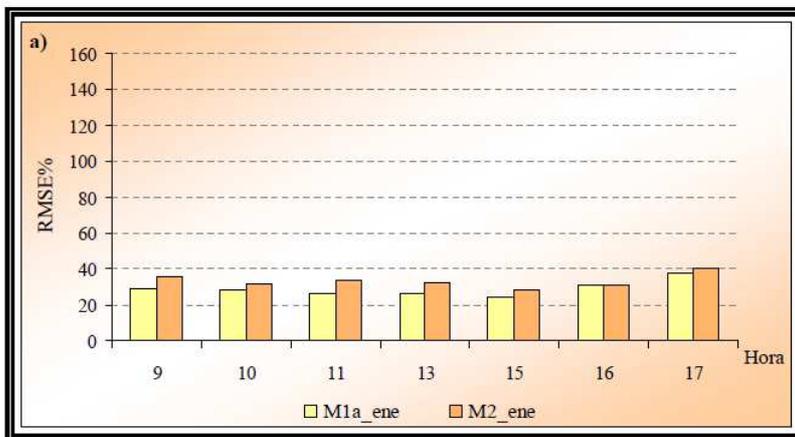


Figura 3: Comparación de dos modelos para diferentes meses: a) enero y b) junio.

CONCLUSIONES

Los resultados del presente trabajo permiten concluir que las redes neuronales de tipo perceptrón multicapa son adecuadas para realizar buenas estimaciones de la radiación solar horaria, aún usando como única variable la temperatura.

Los resultados obtenidos muestran que sin datos de heliofanía también es posible estimar la radiación solar horaria satisfactoriamente a partir de variables normalmente provistas por estaciones meteorológicas de uso extendido en Argentina.

Debido a que se consideraron variables de fácil obtención como datos de entrada de la red, estos modelos podrían aplicarse a cualquier sitio que cuente con una estación meteorológica básica.

AGRADECIMIENTOS

Los autores desean agradecer a:

- SECYT de la Universidad Nacional de Córdoba por el apoyo económico brindado.
- Los Sres. Eduardo e Ignacio Urcullu por facilitar los datos y la información sobre la estación meteorológica.

REFERENCIAS

- Al-Alawi, S. M. y Al-Hinai, H. A. (1998). An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. *Renewable Energy* **14**, 1-4, 199–204.
- Bocco, M.; Ovando, G. y Sayago, S. (2006). Development and evaluation of neural network models to estimate daily solar radiation at Córdoba, Argentina. *Pesquisa Agropecuária Brasileira* **41**, 2, 179–184.
- Bocco, M.; Willington, E. y Arias, M. (2010). Comparison of Regression and Neural Networks Models to Estimate Solar Radiation. *Chilean J. Agric. Res.* **70**, 3, 428–435.
- Chen, R.; Kang, E.; Ji, X.; Yang, J. y Wang, J. (2007). An hourly solar radiation model under actual weather and terrain conditions: A case study in Heihe river basin. *Energy* **32**, 1148–1157.
- Di Rienzo, J.; Casanoves, F.; Balzarini, M.; González, L.; Tablada, M. y Robledo, C. InfoStat versión 2010. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina.
- Elminir, H. K.; Azzam, Y. A. y Younes, F. I. (2007). Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy* **32**, 1513–1523.
- Fadare, D. A.; Irimisose, I.; Oni, A. O. y Falana, A. (2010). Modeling of solar energy potential in Africa using an artificial neural Network. *American Journal of Scientific and Industrial Research* **1**, 2, 144–157.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. The Knowledge Engineering Review Prentice Hall, Upper Saddle River, NJ **13**, 409–412.
- Hilera González, J. R. y Martínez Hernando, V. J. (2000). *Redes neuronales artificiales: fundamentos modelos y aplicaciones*. 1ra. Edición, 390p. Editorial Alfaomega Ra-Ma, Colombia.
- Hocaoğlu, F. O.; Gerek, Ö. N. y Kurban, M. (2007). A novel 2-D model approach for the prediction of hourly solar radiation. *LNCS Springer* **4507**, 741–749.
- Hocaoğlu F. O.; Gerek, Ö. N., y Kurban, M. (2008). Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward neural networks. *Solar Energy* **82**, 714–26.
- Kaplanis, S. y Kaplani, E. (2010). Stochastic prediction of hourly global solar radiation for Patra, Greece. *Applied Energy* **87**, 3748–3758.
- Krishnaiah, T.; Srinivasa Rao, S.; Madhumurthy, K. y Reddy, K. S. (2007). Neural Network Approach for Modelling Global Solar Radiation. *Journal of Applied Sciences Research* **3**, 10, 1105–1111.
- Leal, S. S.; Tiba, C. y Piacentini, R. D. (2009). Modelos estadísticos para determinação da irradiação solar UV diária no estado de Pernambuco. *Avances en Energías Renovables y Medio Ambiente* **13**, 11.41–11.47.
- Li, B. (2002). *Spatial interpolation of weather variables using artificial neural networks*. Athens – University of Georgia, 89p. (Tesis de maestría). Disponible en: http://www.ai.uga.edu/iai/Theses/li_bin.pdf
- Mahibbur, R. M. y Govindarajulu, Z. (1997). A modification of the test of Shapiro and Wilks for normality. *Journal of Applied Statistics* **24**, 2, 219–235.
- Mellit, A.; Benghanem, M. y Bendekhis M. (2005). Artificial neural network model for prediction solar radiation data: application for sizing stand-alone photovoltaic power system. In: *Proceedings of IEEE Power Engineering Society. General Meeting, USA* **1**, 40–44.
- Menges, H. O.; Ertekin, C. y Sonmete, M. H. (2006). Evaluation of global solar radiation models for Konya, Turkey. *Energy Conversion and Management* **47**, 3149–3173.
- Moody, J. O. y Antsaklis, P. J. (1996). The dependence identification neural network construction algorithm. *IEEE Transactions on Neural Networks* **7**, 1, 3–15. Disponible en: http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=478388
- Raichijk, C.; Grossi Gallegos H. y Righini R. (2005). Evaluación de un método alternativo para la estimación de valores medios mensuales de irradiación global en Argentina. *Avances en Energías Renovables y Medio Ambiente* **9**, 11.05–11.08.
- Raichijk, C. (2008). Estimación de la irradiación solar global en Argentina mediante el uso de redes neuronales artificiales. *Energías Renovables y Medio Ambiente* **22**, 1–6.
- Raichijk, C.; Fasulo, A. y Grossi Gallegos, H. (2009). Estudio de validación de las correlaciones para la fracción difusa de la irradiación solar en San Luis. *Avances en Energías Renovables y Medio Ambiente* **13**, 11.17–11.24.
- Reddy, K. S. y Ranjan, M. (2003). Solar resource estimation using artificial neural networks and comparison with other correlation models. *Energy Conversion and Management* **44**, 2519–2530.

- Roldán, A.; Righini, R. y Grossi Gallegos, H. (2005). Análisis preliminar del comportamiento de fajas de heliógrafos utilizadas en Argentina. *Avances en Energías Renovables y Medio Ambiente* **9**, 11.09–11.13.
- Siqueira, A. N.; Tiba, C. y Fraidenraich, N. (2006). Geração da irradiação solar diária, mediante redes neurais artificiais. *Avances en Energías Renovables y Medio Ambiente* **10**, 11.107-11.113.
- Soares, J.; Oliveira, A. P.; Božnar, M. Z.; Mlakar, P.; Escobedo, J. F. y Machado, A. J. (2004). Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. *Applied Energy* **79**, 201–214.
- SOLPOS - MIDC (Measurement and Instrumentation Data Center). (2011). Disponible en <http://www.nrel.gov/midc/solpos/solpos.html>
- Spokas, K. y Forcella, F. (2006). Estimating hourly incoming solar radiation from limited meteorological data. *Weed Science* **54**, 182–189.
- Toğrul, I. y Toğrul, H. (2002). Global solar radiation over Turkey: Comparison of predicted and measured data. *Renewable Energy* **25**, 1, 55–67.

ABSTRACT

Estimating incident Earth's surface solar radiation is very important, since it is the main source of renewable energy in nature and because its measurement is difficult and costly. Numerous estimation models have been developed, including neural networks that present an alternative that overcomes conventional approaches. The aim of this work was to develop neural networks capable to estimate hourly solar radiation using hourly meteorological variables of easy measure. For this, six neural network models were built whose input data were: temperature, relative humidity, wind speed and rainfall, obtained using an automatic weather station in the province of Cordoba. The results showed a good networks' performance in the estimation of radiation, with determination coefficients between 0.80 and 0.86, and RMSE% values between 25% and 48% for a particular model. It can be concluded that neural networks allow good estimates of hourly solar radiation.

Keywords: Neural networks, solar energy, renewable energy.