

Direct and diffuse solar radiation determination at the Venezuelan seashore by using meteorological variables

**Julio Rafael Gómez Sarduy^{1*}, Juan Francisco Puerta Fernández¹,
Antonietta González Alén², Meybol Gessa Gálvez¹**

¹Centro de Estudios de Energía y Medio Ambiente, Universidad de Cienfuegos
"Carlos Rafael Rodríguez". Carretera a Rodas, km 4, Cienfuegos, Cuba.
Telf.: 53-043-500137. *jgomez@ucf.edu.cu

²Fundación para el Desarrollo del Servicio Eléctrico (FUNDELEC).
Ministerio del Poder Popular para la Energía Eléctrica, Venezuela.

Abstract

Modeling of solar radiation, as a function of meteorological variables of the Venezuelan seashore in the period between 2005 and 2009, was developed using artificial intelligence tools as artificial neural networks (ANN). With a combination of ANN and the Erbs model is calculated the direct and diffuse radiations and clearness index. The modeling results may be useful to design the solar systems therefore constitutes a tool for efficient use of these systems. Comparison of modeling with data for 2010 Mene Grande station is performed and its excellent predictive capability is verified. This study determined that the diffuse radiation in the Venezuelan seashore with climate classification Bs (steppe climate) is 8.54 MJ/m² whereas for places with climate classification Aw (tropical wet and dry or savanna climate) is slightly higher and in the order of 9.12 MJ/m². Results of the proposed model are compared with the other ones, calculated by astronomical factors and its excellent performance is verified.

Keywords: solar radiation, direct radiation, diffuse radiation, artificial neural network, clearness index.

Determinación de la radiación solar directa y difusa en la zona de la costa venezolana a partir de variables meteorológicas

Resumen

Se desarrolla la modelación de la radiación solar en función de las variables meteorológicas de la zona costera venezolana en el período comprendido entre el año 2005 y 2009, para ello se aplican herramientas de inteligencia artificial, específicamente redes neuronales artificiales (RNA). Combinando las RNA y el modelo de Erbs se calculan las componentes directa y difusa de la radiación global y los respectivos índices de claridad. Los productos de la modelación se recomiendan para obtener la información necesaria para el diseño de sistemas basados en energía solar, por lo que constituye una herramienta que incide en el aprovechamiento eficiente de estos sistemas. Se realiza la comparación de la modelación con los datos correspondientes a 2010 de la estación de Mene Grande y se verifica su excelente capacidad de predicción. Con este estudio se determina que la radiación difusa de la zona de la costa venezolana con clasificación climática Bs (seco de estepa) es de 8.54 MJ/m² aproximadamente mientras que para los lugares con clima

A_w (tropical húmedo y seco) es ligeramente superior y en el orden de 9.12 MJ/m^2 . Los resultados se comparan con los calculados utilizando factores astronómicos y se comprueba su excelente desempeño.

Palabras clave: radiación solar, radiación directa, radiación difusa, red neuronal artificial, índice de claridad.

1. Introducción

Sobre la atmósfera se recibe un promedio de radiación solar (constante solar) de 1367 W/m^2 , pero a nivel del suelo la radiación varía entre 0 y 1000 W/m^2 . Esta atenuación de los valores de radiación y su variabilidad en el tiempo se debe a varios factores, como son los efectos de absorción y difusión de la atmósfera, factores astronómicos, efectos meteorológicos, etc. Esto hace que la radiación solar recibida sobre la superficie horizontal de la tierra pueda cambiar drásticamente.

Por otro lado, para el diseño de numerosas aplicaciones de sistemas energéticos, como la solar térmica, fotovoltaica o edificios de energía casi cero, es necesario conocer la radiación solar disponible en superficies inclinadas. El cálculo de la radiación solar que incide sobre una superficie inclinada precisa determinar las componentes directa y difusa de la radiación ya que sus diferentes naturalezas físicas determinan cómo se proyectan sobre la superficie en cuestión.

Existen instrumentos para medir directamente ambas componentes, sin embargo, son dispositivos complejos con altos costos de mantenimiento. Esto explica la poca disponibilidad de este tipo de datos en comparación con los valores de la radiación solar global. Una solución ha sido proponer modelos aproximados para calcular estas componentes a partir de los datos disponibles. Algunos modelos simulan la interacción de la componente solar directa con la atmósfera y dan los flujos en la superficie como una de sus salidas, como es el caso de varios modelos numéricos de predicción del clima, por ejemplo el reportado en Skamarock *et al.* [1] y otros integrados a sistemas de información geográfica [2-6]. Con los primeros se alcanza una alta resolución pero son complejos y con un alto costo computacional, con los segundos la precisión empeora ya que se basan en modelos que dan estimaciones relativamente precisas en condiciones de cielo claro. También se han desarrollado modelos estadísticos que relacionan la radiación global medida con datos de radiación directa y difusa. En estos modelos se incorporan

también otras variables astronómicas y meteorológicas. Por la complejidad de la evaluación de las componentes directa y difusa, aún se continúa investigando en el desarrollo de métodos para su estimación, incorporando técnicas de inteligencia artificial [7-10].

Dada la importancia de las componentes directa y difusa para la selección y utilización de sistemas de energía solar (colectores, concentradores y otros.) y para la arquitectura bioclimática en general, es una imperiosa necesidad estimar estos valores con la mayor aproximación posible con la información y los medios disponibles. Las posibilidades para modelar el índice de claridad y por ende la radiación directa y difusa, en función de variables meteorológicas disponibles en las estaciones fue desarrollado por primera vez en Venezuela [11], no obstante, el modelo estadístico obtenido es válido sólo para el estado de Bolívar y no considera la variabilidad del tipo de clima. Por esta razón, es necesaria la búsqueda de nuevos modelos más generales que incorporen además la clasificación climática.

En este trabajo se reporta la modelación del índice de claridad para la zona costera de Venezuela considerando la influencia de las variables meteorológicas y el tipo de clima, calculando las componentes directa y difusa de la radiación solar empleando la combinación de redes neuronales artificiales y el modelo de Erbs de manera más completa que los modelos estadísticos existentes [12].

2. Metodología para la obtención del modelo

Cuando no se dispone de mediciones de la radiación directa y difusa, estas componentes se pueden calcular a partir de la obtención de los modelos que describen su comportamiento en función de parámetros meteorológicos disponibles. Todos los modelos existentes para el cálculo de las componentes directa y difusa de la radiación solar requieren del índice de claridad. Este índice de claridad se calcula en función de facto-

res astronómicos solamente (latitud, declinación terrestre, ángulo horario y día del año). En esta sección se expone una síntesis de un método para la obtención de un modelo neuronal para el cálculo de la radiación directa y difusa en la zona de la costa venezolana a partir de variables meteorológicas considerando lo siguiente:

1. Se calcula la radiación directa y difusa utilizando el índice de claridad diario (K_T).
2. Se utiliza para la clasificación climática el **Sistema de Koeppen** [13] y se consideran los siguientes tipos climáticos para la región estudiada: Coro, Maracaibo, Maiquetía y Mene Grande clima Bs o sea, seco de estepa; Barcelona, Cumaná, Margarita y Güiría clima Aw o sea, tropical húmedo y seco.

El esquema general se muestra en la Figura 1.

El modelo utilizado para el cálculo de la radiación extraterrestre a partir de los datos astronómicos está definido por la latitud (Φ), la declinación de la tierra (δ), el ángulo horario (ω) y el día del año (n). Para ello se calcula la declinación como:

$$\delta = 23,45 \operatorname{sen} \left[\frac{360(n + 284)}{365} \right] \quad (1)$$

siendo n el día del año a partir del primero de enero. Se desprecian los días 29 de febrero de los años bisiestos.

A partir de la declinación se calcula para cada día el ángulo horario del ocaso solar como:

$$\omega_s = \arccos(-\tan(\delta)\tan(\Phi)) \quad (2)$$

Con los valores de δ y ω_s se calcula la radiación solar extraterrestre como:

$$H_o = \left(\frac{24}{\pi} \right) I_{cs} E_o \cos(\Phi) \cos(\delta) \left(\operatorname{sen} \omega_s - \left(\frac{\pi}{180} \right) \omega_s \cos \omega_s \right) \quad (3)$$

Siendo I_{cs} la constante solar igual a 1367 W/m^2 o $4921 \text{ kJ/m}^2\text{h}$ y E_o la constante de corrección de la distancia tierra-sol para un día cualquiera del año que se calcula como:

$$E_o = 1 + 0,033 \cos \left(\frac{2n\pi}{365} \right) \quad (4)$$

Como se muestra en la Figura 1 el índice de claridad se obtiene de un modelo neuronal cuyas entradas son los datos meteorológicos y la clasificación climática de la zona que se analiza, haciéndose independiente de los parámetros astronómicos. Sin embargo, se calculó el índice de claridad a partir de estos últimos y se empleó como prototipo numérico para generar los datos de índice de claridad para el entrenamiento de la red. El índice de claridad se calcula como:

$$K_T = \frac{H}{H_o} \quad (5)$$

siendo H la radiación medida sobre un plano horizontal en la superficie de la tierra que es una de las variables medidas.

El valor de K_T calculado por la expresión (5) no considera las variables meteorológicas ni la clasificación climática de la zona, y los mode-

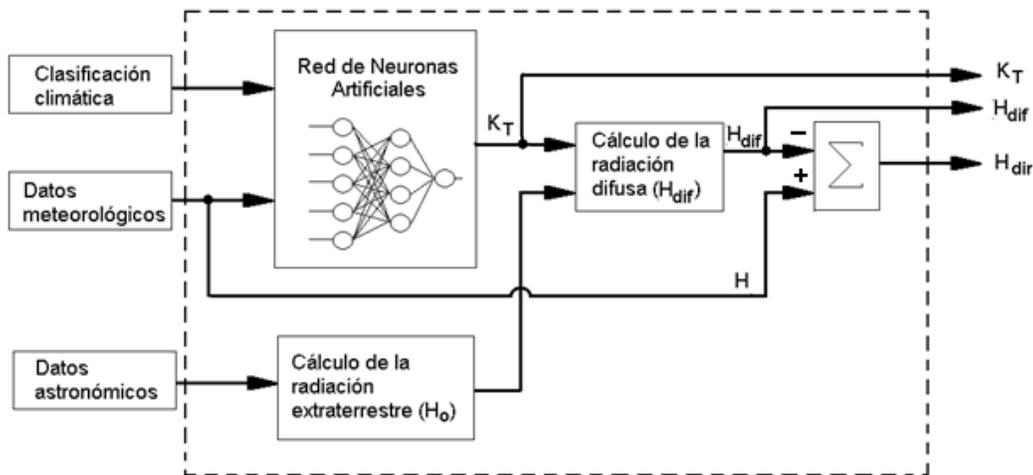


Figura 1. Diagrama general del modelo para el cálculo de la radiación directa y difusa.

los obtenidos por Amézquita [11] son modelos estadísticos en función de variables diferentes para cada zona del estado de Bolívar. Un modelo general que correlacione variables semejantes para cada zona con el índice de claridad puede obtenerse empleando técnicas de Inteligencia Artificial, en particular redes neuronales artificiales; (RNA). Las RNA pueden ser aplicadas para conseguir un modelo a partir de los datos meteorológicos reales y los valores de K_r calculados por (5) fueron utilizados como objetivos (targets) en el entrenamiento de la red. La utilidad de emplear RNA radica principalmente en que no se necesita conocer el proceso físico del sistema en sí mismo, siendo suficiente correlacionar las variables de entrada y salida de dicho sistema. A continuación se exponen los fundamentos necesarios para la comprensión del modelo obtenido.

2.1. Diseño y entrenamiento de las RNA

Para el diseño y entrenamiento de las RNA se emplea la herramienta de redes neuronales **nftool** del Toolbox del Matlab 10.0. Las redes propuestas son de tres capas con propagación hacia adelante y algoritmo de aprendizaje con retropropagación. El vector de entrada está definido por los valores normalizados de la radiación media diaria (H), la temperatura media (Tmed), humedad máxima (Humax), humedad mínima (Humin), humedad media (Humed), nubosidad (Nub), insolación (Insol), temperatura de bulbo húmedo (Tbh) y velocidad del viento (Vv). Los valores medios fueron calculados a partir de mediciones horarias. La salida de la red es el índice de claridad (K_r) y su arquitectura se muestra en la Figura 2.

La función transferencia de las neuronas de la capa oculta es *tansig* y la de la neurona de la última capa es *purelin*. Las variables para el entrenamiento y validación se corresponden con valores experimentales medidos en las estaciones

de la costa (Coro, Barcelona, Maiquetía, Margarita, Cumaná, Güiría, Maracaibo y Mene Grande) en el periodo comprendido 2005-2009. Para el entrenamiento se selecciona un 15% de los datos para validación y un 15% para prueba, dejando el 70% para entrenamiento. Los datos de prueba permiten comprobar durante la etapa de entrenamiento la capacidad de generalizar que tiene la red diseñada, o sea, cuán bien responde ante datos que no se encuentran dentro del conjunto de entrenamiento. Los datos de validación tienen el mismo propósito, pero son capaces de abortar el entrenamiento cuando las tendencias de comportamiento son diferentes. El algoritmo de entrenamiento seleccionado fue el Levenberg-Marquart (TRAINLM) y la función de comportamiento fue el error medio cuadrático (MSE).

2.2. Análisis post-entrenamiento

El primer análisis que se realiza consiste en simular la red para todo el universo de datos disponibles (entrenamiento, prueba y validación) y realizar una regresión lineal entre la salida de la red y los objetivos correspondientes (valores experimentales). El resultado es que los valores de K_r obtenidos por los modelos neuronales siguen razonablemente bien los valores calculados por (5) con coeficientes de correlación $R^2 > 0,98$ lo que sirve de validación al modelo. Los errores se ajustan a una distribución normal con los parámetros que se muestran en la Tabla 1.

Tabla 1
Parámetros de la distribución de los errores de las redes neuronales

RNA	Clima_Bs	Clima_Aw
μ	0,000551044	0,000919705
σ	0,0259438	0,0294483

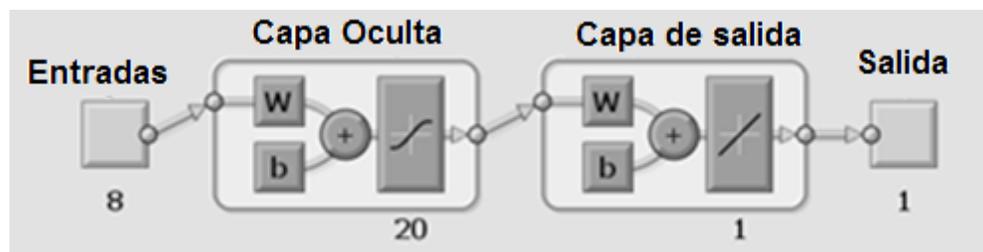


Figura 2. Arquitectura de las redes diseñadas.

La incertidumbre del resultado de la red se puede calcular con un 95% de confianza como: $\mu \pm 2\sigma$, donde μ es el valor medio de los errores del modelo y σ la desviación estándar.

Para el caso de la red Clima_Bs este intervalo es (-0,051, 0,052). Para el caso de la red Clima_Aw este intervalo es (-0,058, 0,0598).

2.3. Cálculo de la radiación directa y difusa

La radiación difusa se calcula en función de la radiación global y del índice de claridad, o sea:

$$H_{dif} = f(H, K_T) \quad (6)$$

Esta se calcula a partir del modelo de Erbs que se presenta en las expresiones (7) a la (10):

Para $\omega_s \leq 81,4^\circ$ y $K_T < 0,715$:

$$\frac{H_{dif}}{H} = 1 - 0,2727K_T + 2,4495K_T^2 - 11,9514K_T^3 + 9,3879K_T^4 \quad (7)$$

Para $\omega_s \leq 81,4^\circ$ y $K_T \geq 0,715$:

$$\frac{H_{dif}}{H} = 0,143 \quad (8)$$

Para $\omega_s > 81,4^\circ$ y $K_T < 0,722$:

$$\frac{H_{dif}}{H} = 1 + 0,2832K_T - 2,5557K_T^2 + 0,8448K_T^3 \quad (9)$$

Para $\omega_s > 81,4^\circ$ y $K_T \geq 0,722$:

$$\frac{H_{dif}}{H} = 0,175 \quad (10)$$

3. Análisis de resultados

Internacionalmente se han realizado diferentes investigaciones que muestran un comportamiento similar de la fracción de la radiación difusa sobre superficies horizontales en función del índice de claridad. Una correlación semejante se plantea en la Figura 3 para la zona de la costa venezolana a partir de los resultados del modelo neuronal desarrollado y se observa que sigue el mismo comportamiento que el especificado por los estudios realizados para distintas regiones del planeta.

El comportamiento del índice de claridad o transparencia de la atmósfera se ajusta a una distribución gaussiana con $\mu=0,44$ y $\sigma=0,16$, calculados utilizando la herramienta dfittool de Matlab [12]. La curva de probabilidad acumulativa se muestra en la Figura 4 donde se puede observar que la probabilidad de que el índice de claridad sea menor de 0,5 es del orden del 64% aproximadamente. Si esto se asocia con los resultados mostrados en la Figura 3, se puede entonces inferir que hay un 64% de probabilidad de que la fracción de radiación difusa sea igual o superior a la fracción de radiación directa para esta zona.

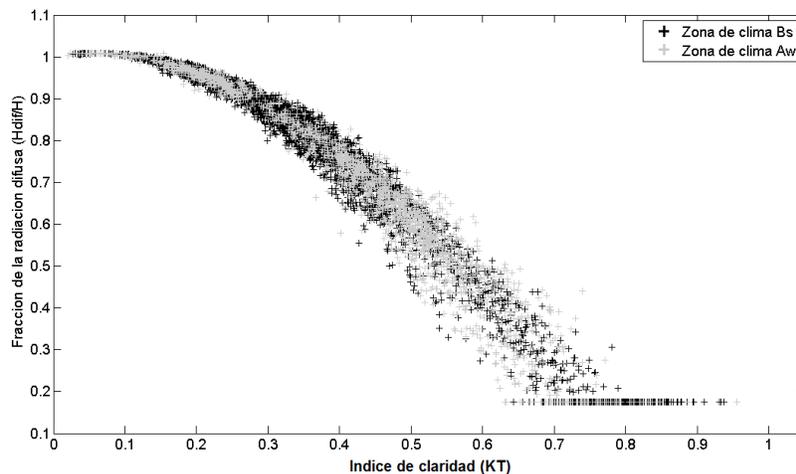


Figura 3. Fracción difusa de la radiación diaria en función del índice de claridad K_T .

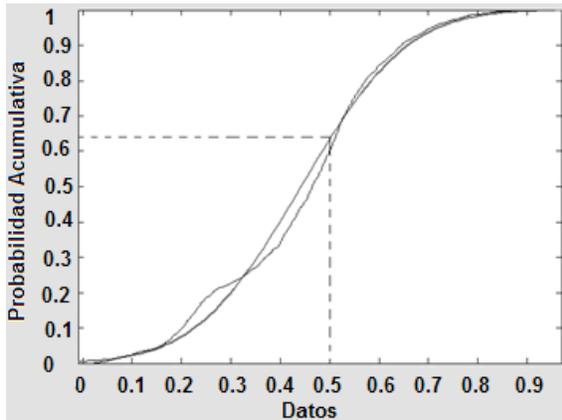


Figura 4. Distribución del índice de claridad para la zona con clima Aw [12].

3.1. Análisis de resultados

Con una muestra de 346 elementos seleccionados para los datos de clima Bs, se calculó la radiación directa y difusa por el método de Erbs. Los resultados obtenidos por el modelo propuesto, que incluye las RNA, se corresponden con los resultados del método convencional que calcula el índice de claridad directamente por la ecuación (5). Si se considera el método convencional en el cual se mide H y se calcula H_0 con los datos astronómicos como referencia, el error del modelo propuesto es del orden de $\pm 1 \text{ MJ/m}^2$. Con el objetivo de apreciar bien los resultados gráficamente, solo se exponen en la Figura 5 los resultados para 100 elementos de la muestra. La radiación directa también exhibe el mismo comportamiento (Figura 6). Para la

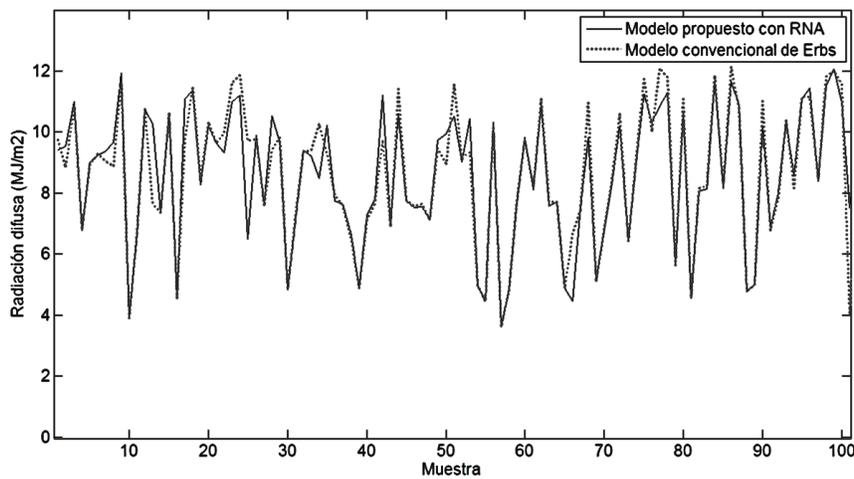


Figura 5. Radiación difusa por RNA para la zona con clima Bs y por el método convencional.

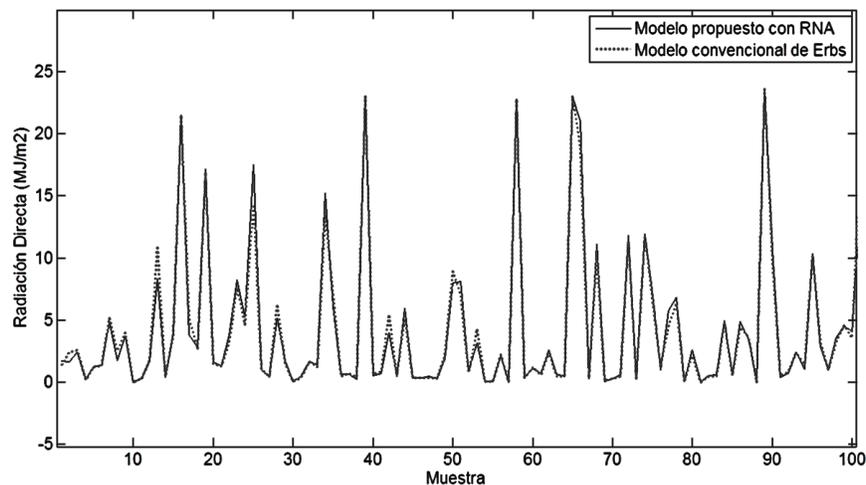


Figura 6. Radiación directa por RNA para la zona con clima Bs y por el método convencional.

zona climática Aw se selecciona una muestra de 320 elementos. Tanto para el caso de la radiación difusa como para la directa, se aprecia que hay correspondencia con el método convencional (ver Figuras 7 y 8 para 100 elementos de la muestra). El valor esperado de los errores es de $0,35 \text{ MJ/m}^2$.

3.3. Resultados con los datos del 2010

Con el modelo propuesto se pueden realizar pronósticos de la radiación si se conoce el de las variables meteorológicas involucradas. Con el objetivo de verificar la calidad de un pronóstico con el modelo desarrollado se utilizan los datos del año 2010, los cuales no fueron utilizados ni para el entrenamiento, ni para la validación ni para la

prueba durante el proceso de aprendizaje de las redes neuronales artificiales. Los resultados comparativos de los dos modelos (sólo para el mes de enero) se observan en las Figuras 9 y 10 para la radiación difusa y directa respectivamente en la estación meteorológica de Mene Grande. Se puede observar que la respuesta de los dos modelos consigue el mismo comportamiento para ambos tipos de radiaciones de manera que el método puede ser empleado como un predictor en el caso de que se tenga un pronóstico de las variables meteorológicas y se requiera estimar la radiación. Se calculó la diferencia entre los valores de radiación estimados por el modelo de Erbs y los estimados por el modelo propuesto en este trabajo. El valor medio de la diferencia entre los dos modelos

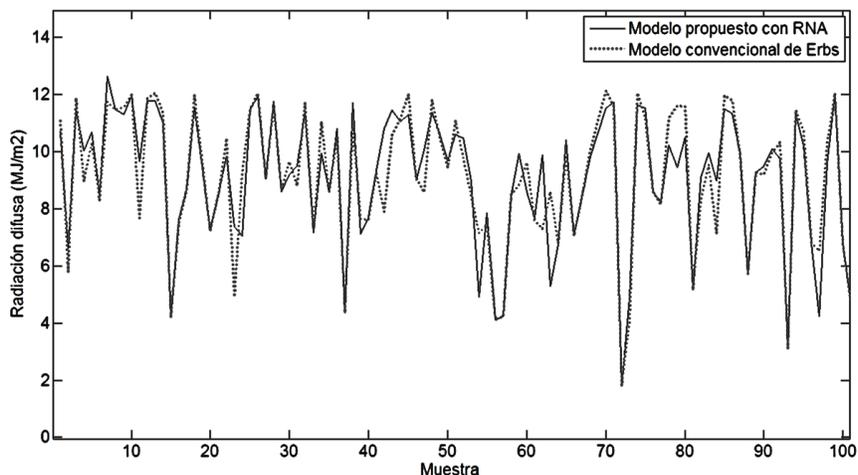


Figura 7. Radiación difusa por RNA para la zona con clima Aw y por el método convencional.

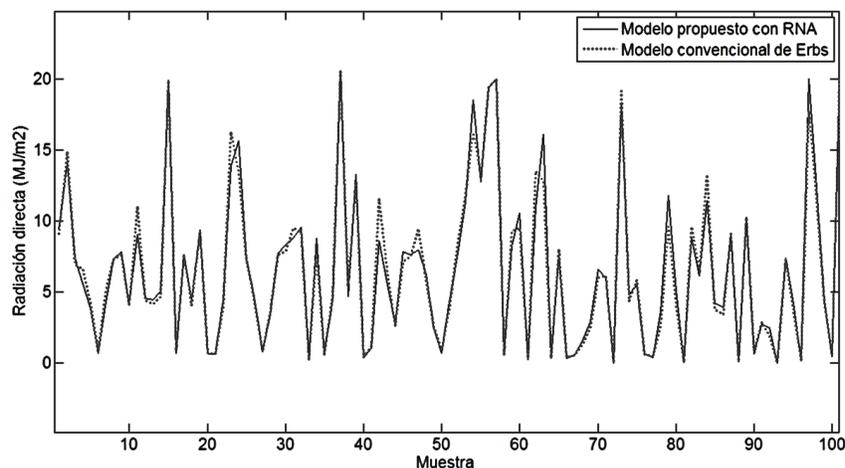


Figura 8. Radiación directa por RNA para la zona con clima Aw y por el método convencional.

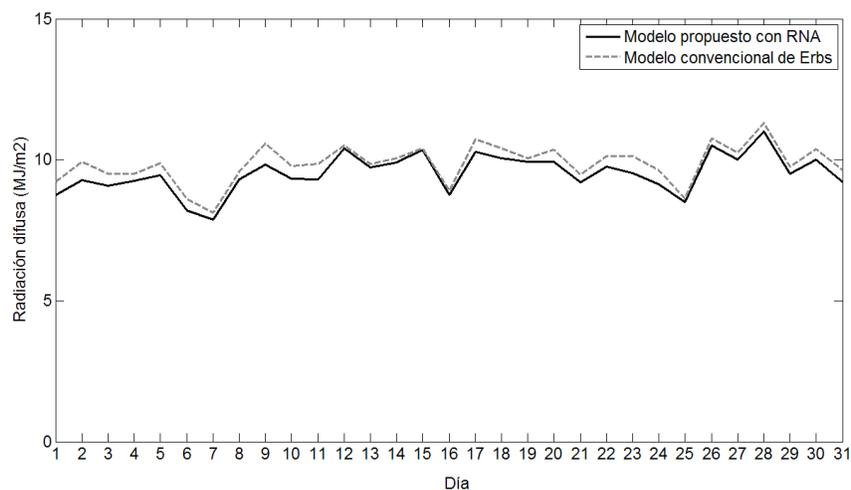


Figura 9. Radiación difusa estimada con RNA y método de Erbs (Mene Grande, enero 2010).

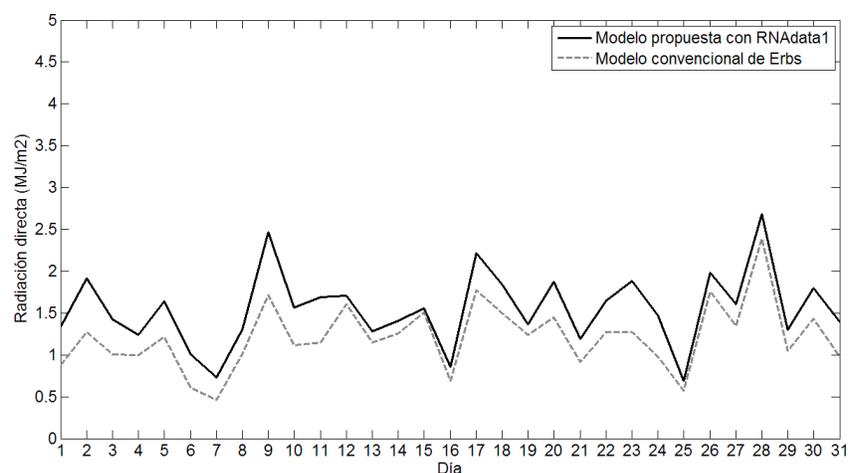


Figura 10. Radiación directa estimada con RNA y método de Erbs (Mene Grande, enero 2010).

(tanto para las componentes difusa y directa) es de $0,13 \text{ MJ/m}^2$ con una desviación estándar calculada de $0,73$.

Como se aprecia en las Figuras 9 y 10, debido a que la radiación directa (para cualquiera de los dos métodos) se calcula a partir de la diferencia entre la radiación global y la difusa, cuando con el modelo propuesto se subestime la radiación difusa con relación al de Erbs, el resultado será una sobrestimación de la radiación directa y viceversa.

4. Conclusiones

Los modelos obtenidos, basados en RNA, consideran los factores meteorológicos que se mi-

den normalmente y responden satisfactoriamente al correlacionar con los datos experimentales con un $R^2 > 0,97$ para todos los casos. Estos incorporan de manera implícita la clasificación climática de la zona al diseñar una red para el tipo de clima Bs y otra para el tipo Aw.

Se puede afirmar que la variabilidad del tipo climático para la región de la costa venezolana tiene poca influencia y la relación establecida entre la fracción de radiación difusa y el K_T calculado por la RNA es similar para ambos tipos de clima.

Los modelos neuronales desarrollados tienen la ventaja de que pueden ser reentrenados con datos actualizados por lo que cada cierto tiempo se puede corregir cualquier desviación en

los mismos y además, pueden ser utilizados con el propósito de mejorar cuantitativamente el pronóstico de la radiación o realizar estudios prospectivos, lo cual se comprobó para el caso de la estación de Mene Grande con los datos del 2010.

Agradecimientos

Los autores agradecen la colaboración de la Dirección de Meteorología de la Aviación Militar Bolivariana, del Ministerio del Poder Popular para la Energía Eléctrica, a la Fundación para el Desarrollo del Servicio Eléctrico (FUNDELEC) y a la Universidad Nacional Experimental "Rafael María Baralt" por el apoyo brindado para la realización de esta investigación.

Referencias bibliográficas

3. Skamarock W.C., Klemp J.B., Dudhia J., Gill D.O., Barker D.M., Wang W., Power, J.G.: "A description of the advanced research WRF version 2". NCAR Technical Note, NCAR/TN-468+STR, (2005). Disponible en http://www.mmm.ucar.edu/wrf/users/docs/arw_v3.pdf.
4. Rigollier C., Bauer O., Wald L.: "On the clear sky model of the ESRA - European Solar Radiation Atlas - with respect to the Heliosat method". *Solar Energy*, Vol. 68, No.1 (2000) 33-48.
5. Wilson J.P. and Gallant J.C.: Secondary topographic attributes. In: Wilson J.P., Gallant J.C. (ed), *Terrain analysis: principles and applications*, John Wiley and Sons; USA (2000) 91-105.
6. Mészáros I., Miklánek P., Parajka J.: "Solar energy income modelling in mountainous areas". RB and NEFRIEND Proj. 5 Conference on interdisciplinary approaches in small catchment hydrology: Monitoring and Research. Slovak NC IHP UNESCO/UH SAV: Bratislava, Slovakia, (2002) 127-135.
7. Sári M., Hofierka J.: "A new GIS-based solar radiation model and its application to photovoltaic assessments". *Trans GIS*, Vol. 8, No. 2 (2004)175-190.
8. Ruiz Arias J.A., Alsamamra H., Tovar Pescador J., Pozo Vázquez D.: "A comparative analysis of DEM-based models to estimate the solar radiation in mountainous terrain". *International Journal of Geographical Information Science*, Vol. 23, No. 1, (2009)1049-1076.
9. Ruiz Arias J.A., Alsamamra H., Tovar Pescador J., Pozo Vázquez D.A.: "Proposal of a regressive model for the hourly diffuse solar radiation under all sky conditions". *Energy Conversion and Management*, Vol. 51, No. 5, (2010) 881-893.
10. López G., Batlles F.J., Tovar-Pescador J.: "Selection of input parameters to model direct solar irradiance by using artificial neural networks". *Energy* Vol. 30, No. 9, (2005) 1675-1684.
11. Linares Rodríguez A., Ruiz Arias J.A., Pozo Vázquez D., Tovar Pescador J.: "Generation of synthetic daily global solar radiation data based on ERA-Interimre analysis and artificial neural networks". *Energy*, Vol. 36, No. 8, (2011) 5356-5365.
12. Mohandes M. A.: "Modeling global solar radiation using Particle Swarm Optimization (PSO)". *Solar Energy*, Vol. 86, No. 11, (2012) 3137-3145.
13. Amézquita, U.: "Estudio estadístico de la radiación solar global en el estado Bolívar y la influencia de las variables meteorológicas en el índice de claridad". Tesis para optar por el título de Magister Scientiarium en Ingeniería Mecánica, Universidad Central de Venezuela, (2005).
14. González Alén, A.: "Análisis del comportamiento de la radiación solar y de las variables meteorológicas sobre el índice de claridad en la zona costera venezolana como una herramienta para la eficiencia energética". Tesis para optar por el grado académico de Máster en Eficiencia Energética, Universidad de Cienfuegos "Carlos Rafael Rodríguez", (2012).
15. McKnight T. L. and Hess D.: "Climate Zones and Types: Highland Climate (Zone H)". *Physical Geography: A Landscape Appreciation*. Upper Saddle River, Prentice Hall., N.J., 2000.

Recibido el 16 de Enero de 2014

En forma revisada el 23 de Marzo de 2015