



“II Congreso Argentino de Energías Sustentables”

**Facultad Regional Bahía Blanca, Universidad Tecnológica Nacional.
Universidad Nacional del Sur.
Universidad Nacional del Comahue.**

ENTRENAMIENTO DE UNA RED NEURONAL ARTIFICIAL PARA LA PREDICCIÓN DE LA RADIACIÓN SOLAR

Morales, D. Martín^(1,2), Cappelletti, Marcelo^(1,3),
Hasperué, Waldo^(1,4), Charlier, Leandro^{(1)*}

(1) *Instituto de Ingeniería y Agronomía, Universidad Nacional Arturo Jauretche.*
martin.morales@unaj.edu.ar

(2) *Universidad Tecnológica Nacional, Facultad Regional La Plata (UTN, FRLP),
Laboratorio de Ingeniería en Sistemas de Información (LINES).*

(3) *Facultad de Ingeniería, Universidad Nacional de La Plata (UNLP),
Grupo de Estudio de Materiales y Dispositivos Electrónicos (GEMyDE).*

(4) *Facultad de Informática, Universidad Nacional de La Plata (UNLP),
Instituto de Investigación en Informática LIDI (III-LIDI).*

RESUMEN.

La conversión de energía a través de fuentes de energía renovable y no contaminante se ha tornado un tema trascendente para la humanidad, dado que la evolución y progreso del hombre está ligado a su uso. La principal fuente de energía renovable disponible en la naturaleza es la radiación solar incidente, la cual se presenta como el recurso más promisorio tendiente a sustituir las fuentes de energía no renovables y reducir las emisiones de gases a la atmósfera, dado que permite diversas formas de captación y transformación, principalmente a través de sistemas fotovoltaicos y fototérmicos. Para tener un aprovechamiento óptimo de la energía solar se requiere de un amplio conocimiento acerca de la irradiancia solar incidente a nivel de la superficie terrestre, pero esta magnitud es variable con el tiempo de manera instantánea, horaria, diaria y estacional, con la latitud y con los microclimas locales del sitio. En este trabajo, se presenta el entrenamiento de una red neuronal artificial multicapa para predecir a corto plazo la irradiancia solar en una localidad de la provincia de Córdoba, Argentina. Específicamente, el objetivo del trabajo es analizar diferentes modelos de redes neuronales artificiales capaces de estimar la radiación solar global diaria en dicha localidad. Los modelos considerados difieren entre sí, en la cantidad de neuronas en la capa oculta, en las variables meteorológicas utilizadas como datos de entrada y en el orden cronológico de los datos utilizados para la fase de entrenamiento. En general, los resultados obtenidos han mostrado un aceptable desempeño de la red neuronal artificial en la estimación de la radiación solar, pero con posibilidades ciertas de ser mejorados.

Palabras Claves: energías renovables, radiación solar, redes neuronales artificiales.

1. INTRODUCCIÓN

En los últimos años, la conversión de energía se ha tornado uno de los problemas más importantes a resolver a nivel mundial, dado que la evolución y progreso del hombre está ligado a su uso. La demanda de energía aumenta continuamente. Al día de hoy, los sistemas energéticos basados en recursos fósiles no renovables, como el carbón, el gas natural y el petróleo, cubren aproximadamente el 78.3% de la demanda final global de energía, mientras que el resto se satisface con fuentes de energía renovable (19.1%) y energía nuclear (2.6%) [1]. El 19% correspondiente a la energía renovable es compartido entre la biomasa tradicional (9%), utilizada principalmente para cocinar y para calefacción en áreas rurales de países en vías de desarrollo, y entre fuentes de energía renovables modernas (10%), tales como energía solar, geotérmica, eólica, hidroeléctrica, biocombustibles, entre otras, las cuales son principalmente utilizadas en cuatro mercados diferentes: generación de electricidad; calefacción y refrigeración; transporte; y servicios de energía rural o aislada de la red.

La utilización de recursos fósiles no renovables como fuente de energía, tiene los siguientes inconvenientes:

- los nuevos yacimientos o reservorios resultan de muy difícil acceso, y por lo tanto cada vez más caros de explotar;
- si bien no se agotarán en el corto o mediano plazo se trata de recursos finitos;
- se encuentran concentrados en determinadas regiones, lo cual genera posibles focos de conflictos políticos y militares.
- ocasionan impactos ambientales importantes debido a la emisión de gases tales como dióxido de carbono (CO_2), dióxido de nitrógeno (NO_2) y metano (CH_4), explosiones, derrames, etc., que favorece al calentamiento global y al cambio climático.

Todo esto trajo como consecuencia que en los últimos años comiencen a aparecer nuevos sistemas tecnológicos basados en energías renovables para producir electricidad y calor, con el fin de mejorar la calidad de vida de la humanidad conservando y protegiendo el medio ambiente.

La principal fuente de energía renovable disponible en la naturaleza es la radiación solar incidente, dado que la energía solar recibida anualmente en nuestro planeta es de unas 10000 veces superior al consumo global anual de energía. Por este motivo, la energía solar se presenta como el recurso más promisorio tendiente a sustituir las fuentes de energía no renovables y reducir las emisiones de gases a la atmósfera, dado que permite diversas formas de captación y transformación, principalmente a través de sistemas fotovoltaicos y de sistemas fototérmicos.

Los sistemas fotovoltaicos convierten la luz solar en energía eléctrica y se utilizan no solo para la generación de electricidad, sino también para iluminación, refrigeración y bombeo. Mientras que los sistemas fototérmicos absorben calor directamente y lo transfieren a otro medio como el agua o el aire. Estos incluyen entre otros los sistemas de calentamiento pasivo para el calentamiento de agua, secado y refrigeración, y los sistemas de concentración para la desalación y la desintoxicación y desinfección de agua.

Para tener un aprovechamiento óptimo de la energía solar se requiere de un amplio conocimiento acerca de la irradiación solar incidente a nivel de la superficie terrestre, que permita predecir a corto plazo la producción de energía eléctrica o térmica que potencialmente se podría obtener en un determinado lugar.

La intensidad de radiación solar disponible en un punto determinado de la Tierra es variable con el tiempo de manera instantánea, horaria, diaria y estacional, con la latitud y con los microclimas locales del sitio. Sin embargo, por razones de costos y accesibilidad no siempre es posible contar con datos experimentales de la irradiación solar en superficie en los lugares de interés. Su medición requiere el uso de equipamientos específicos, tales como pirheliómetros y piranómetros, los cuales no resultan económicos de adquirir. La falta de datos medidos de irradiación solar es generalizada a nivel mundial. Hasta el año 2005 solo una de cada 500 estaciones meteorológicas realizaba observaciones de radiación solar incidente [2]. Argentina no es la excepción, en la actualidad la mayoría de las estaciones meteorológicas proveen datos de temperatura, humedad relativa, precipitación y velocidad y dirección del viento. Existe por lo tanto una falta de datos de radiación solar en muchas regiones de nuestro país.

Para subsanar esta limitación se hace necesaria la aparición de métodos alternativos para estimar los valores de irradiación solar en la superficie terrestre a partir de la información meteorológica existente. Entre los diferentes métodos teóricos de estimación se pueden mencionar: modelos lineales, polinómicos, exponenciales y logarítmicos [3], técnicas geoestadísticas [4], técnicas estocásticas [5] y técnicas basadas en imágenes satelitales [6].

En los últimos años, en base al crecimiento de las capacidades de cálculo y al mejoramiento de los algoritmos implementados, se han comenzado a emplear técnicas de inteligencia artificial, tales como redes neuronales artificiales, para predecir los valores de la irradiación solar [7,9]. Los modelos basados en redes neuronales permiten crear modelos de predicción de manera rápida y confiable, pues poseen la capacidad de generalizar y de aprender de patrones de entrada

produciendo valores de salida ante la recepción de estímulos similares. Estos modelos pueden manejar gran cantidad de datos y son sumamente útiles para resolver sistemas complejos y no lineales, mejorando la performance de las técnicas convencionales.

La predicción de la radiación solar que alcanza la superficie de la Tierra es un factor clave en diversas aplicaciones como por ejemplo, en el dimensionamiento de sistemas fotovoltaicos o fototérmicos; en el análisis climático y estimaciones meteorológicas; en las actividades agropecuarias; en la ecología o la hidrología; en el diseño arquitectónico; entre otras.

Este trabajo presenta el entrenamiento de una red neuronal artificial multicapa para predecir a corto plazo la irradiancia solar en la localidad de Capilla de Sitón, situada en el departamento Totoral, provincia de Córdoba, Argentina. Específicamente, el objetivo del trabajo es analizar diferentes modelos de redes neuronales artificiales capaces de estimar la radiación solar global diaria en dicha localidad. Los modelos considerados difieren entre sí, en la cantidad de neuronas en la capa oculta, en las variables meteorológicas utilizadas como datos de entrada y en el orden cronológico de los datos utilizados para la fase de entrenamiento.

Este trabajo se enmarca dentro de una primer etapa de un proyecto cuyo objetivo a largo plazo es el de poder determinar la distribución temporal de la irradiación solar global incidente en diferentes zonas de nuestro país, con el fin de optimizar el diseño de sistemas de aprovechamiento de esta fuente de energía.

2. INTELIGENCIA ARTIFICIAL

El comportamiento de un determinado sistema físico puede ser descrito a partir de modelos matemáticos formulados a través de ecuaciones diferenciales con condiciones de contorno e iniciales determinadas, cuyas incógnitas representan las magnitudes de interés. Tales modelos representan generalmente una simplificación de la realidad, dado que son obtenidos a partir de aproximaciones, sin embargo, si las variables a desprestigiar tienen poco peso en el sistema, serán una buena representación del sistema real.

Obtener la solución exacta de manera analítica puede presentar una gran dificultad, debido a la complejidad natural de las ecuaciones diferenciales o a los inconvenientes que pueden ocurrir con las condiciones de contorno o iniciales.

La simulación numérica se convierte entonces en una etapa indispensable a la hora de estudiar cualquier tipo de sistema, debido al crecimiento de las capacidades de cálculo y velocidad de procesamiento de las computadoras actuales. En este sentido, las técnicas de inteligencia artificial constituyen herramientas poderosas para resolver tales ecuaciones y obtener soluciones muy aproximadas a las soluciones exactas. De esta manera, es posible reproducir resultados experimentales; realizar estudios sobre sistemas, procesos, propiedades o parámetros físicos difíciles de medir de manera experimental reduciendo los tiempos y los costos de los ensayos; analizar, predecir y controlar la respuesta de un sistema determinado bajo diferentes condiciones de operación, con el fin de diseñar el sistema de manera eficiente para obtener la respuesta deseada de una aplicación específica; etc.

El campo denominado Inteligencia Artificial, incluye técnicas tales como: Redes Neuronales Artificiales, Lógica Difusa, Algoritmos Genéticos, Optimización por Enjambre de Partículas y Minería de Datos.

Una de las características de estas técnicas es que son del tipo caja negra, es decir que no permiten obtener una función explícita de las variables físicas involucradas. Sin embargo, ellas tienen el potencial para realizar mejores, más rápidas y más prácticas predicciones que cualquier otro método tradicional. Son capaces de encontrar correlaciones entre datos diversos y han mostrado ser sumamente útiles en áreas tales como ingeniería, análisis de suelos, análisis climático, ecología, análisis genético, robótica, economía, medicina y comunicación, entre otras.

2.1. Redes Neuronales Artificiales.

Las Redes Neuronales Artificiales (RNA) representan una metodología de modelación matemática que permite crear modelos de predicción dado que poseen la capacidad de generalizar y de aprender de patrones de entrada produciendo valores de salida ante la recepción de estímulos similares.

El funcionamiento de las RNA está inspirado en el funcionamiento del sistema nervioso de los seres vivos. Consisten en una arquitectura conformada por un conjunto de neuronas artificiales, las cuales se conectan entre sí por enlaces que transmiten información o estímulos a otras neuronas, a través de funciones matemáticas, para entregar un resultado. Las RNA aprenden de la información histórica, adquiriendo así la capacidad de predecir respuestas del mismo fenómeno. Están organizadas en capas. En general, la mayoría de las arquitecturas poseen una capa de entrada en la cual la red recibe los estímulos externos (datos de entrenamiento o patrones a clasificar), una capa de salida que ofrece la respuesta de la red y una o varias capas intermedias u ocultas, donde se lleva a cabo el procesamiento de la información. La capa de salida incluye tantas neuronas como variables se quieran estimar.

A su vez, en la mayoría de las arquitecturas las neuronas solo se conectan con neuronas pertenecientes a otras capas, aunque se pueden encontrar también arquitecturas donde existen conexiones entre neuronas de la misma capa o incluso entre ellas mismas. La conexión entre las neuronas se realiza a través de la aplicación de funciones matemáticas, tales como la función escalón, la tangente hiperbólica, la función logaritmo, etc. Cada neurona puede recibir uno o más estímulos como entrada, donde cada conexión posee un peso que determina la fuerza del estímulo recibido. La salida de una neurona está dada por la información pesada que recibe y una función de transferencia que determina el valor de salida de dicha neurona. El entrenamiento de una RNA consiste en un proceso iterativo donde mediante alguna técnica preestablecida los pesos de las conexiones de las neuronas se adaptan de tal forma que la red comienza a producir en la salida la información esperada ante una entrada específica. La diferencia entre el valor de salida y el valor observado de la variable a estimar es el error. En este proceso, de manera iterativa se determinan los pesos de las conexiones que permiten corregir dicho error. El entrenamiento finaliza cuando la red es capaz de reproducir las salidas correspondientes a los datos de entrada con un error mínimo elegido o luego de un número establecido de iteraciones.

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.

3. MATERIALES Y MÉTODOS

Actualmente nuestro país cuenta con más de 500 estaciones meteorológicas instaladas a lo largo de todo el territorio, entre aquellas homologadas por el Servicio Meteorológico Nacional y las no homologadas. En particular, el Instituto Nacional de Tecnología Agropecuaria (INTA) dispone de una amplia red de estaciones meteorológicas automáticas para obtener datos agrometeorológicos en todo el país. Estas estaciones meteorológicas están destinadas a medir y registrar regularmente diversas variables, tales como temperatura, precipitaciones, humedad relativa, velocidad y dirección del viento, entre otras. Sin embargo, en general, por su elevado costo de instalación, operación y mantenimiento, la gran mayoría no posee los instrumentos para la medición de la irradiación solar. Por ello se vuelve importante desarrollar metodologías de estimación de la radiación solar a partir de conocer estos registros.

Los datos meteorológicos utilizados en este trabajo corresponden a los valores experimentales diarios provenientes de la estación meteorológica automática tipo Nimbus THP, ubicada en la localidad de Capilla de Sitón (Latitud: -30,572; Longitud: -63,652, Altura: 212 metros), situada en el departamento Totoral, provincia de Córdoba, Argentina, los cuales han sido obtenidos a través del Sistema de Información y Gestión Agrometeorológico (SIGA) [10]. Este sistema de información permite conectarse a la estación a través de internet y monitorear los datos sensados en tiempo real, los cuales se van actualizando cada 10 minutos. Allí se pueden obtener tanto datos actuales, como históricos y estadísticas mensuales.

La estación meteorológica elegida para este trabajo, entró en funcionamiento el 14/04/2015 y cuenta con los instrumentos necesarios para sensor radiación solar global diaria, además de otras variables agrometeorológicas tales como precipitación diaria, temperaturas máxima, mínima y media del aire, humedad relativa media, velocidad media y máxima del viento, duración del follaje mojado, presión de vapor medio, evapotranspiración, punto de rocío, presión atmosférica media y heliofanía relativa, entre otras.

Los datos elegidos para llevar a cabo el entrenamiento de la red neuronal artificial han sido: radiación solar global diaria ($\text{MJ m}^{-2} \text{d}^{-1}$), temperatura máxima y mínima del aire en abrigo a 1,5 metros de altura ($^{\circ}\text{C}$), humedad relativa media (%), velocidad media y máxima del viento (km/h), presión atmosférica media (hPa) y precipitación diaria (mm), en el período comprendido desde el 01/06/2015 hasta el 31/05/2016, abarcando un año completo, por lo que se trabajó con 365 vectores de datos.

La Figura 1 muestra los valores correspondientes a la radiación solar global diaria medida por la estación meteorológica en función de la fecha de registro, siendo *Dato 1* el valor medido el 01/06/2015, *Dato 2* el valor observado el 02/06/2015, y así sucesivamente, hasta *Dato 365* el valor registrado el 31/05/2016.

Como es de esperar, se puede observar en la Figura 1, que los mayores valores de radiación solar ocurren para los valores centrales (aproximadamente entre *Dato 120* y *Dato 300*), los cuales corresponden a los meses entre octubre y marzo.

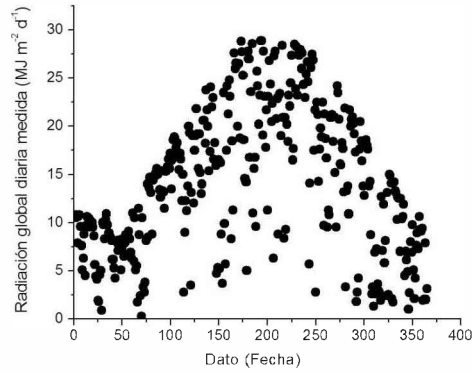


Figura 1 Valores medidos de radiación solar global diaria a lo largo de todo un año.

La metodología utilizada para el entrenamiento de la red neuronal artificial consistió en tres análisis o casos diferentes, de acuerdo a la forma de tomar los datos de entrada provenientes de la estación meteorológica considerada. En todos los casos, se desarrollaron modelos de redes de tipo perceptrón multicapa con propagación de la información hacia adelante. Todos ellos incluyeron una capa de entrada, una capa oculta y una salida que presenta la radiación solar promedio estimada diaria, como se puede observar en la Figura 2 para el caso de 10 neuronas en la capa oculta. Se utilizó como función de relación entre las capas a la función tangente hiperbólica y para finalizar la fase de entrenamiento se consideraron 2000 iteraciones o un error $e < 0,001$. Se utilizó para entrenar el 75 % de los datos, mientras que el 25% restante se lo empleó para la validación de los modelos.

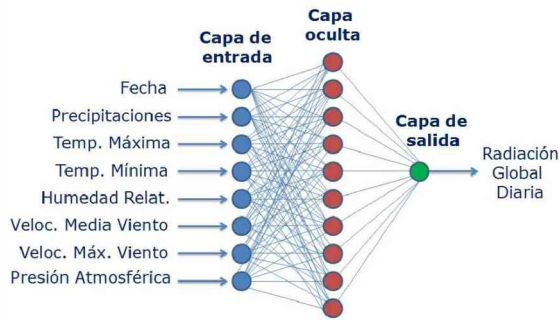


Figura 2 Topología de la red neuronal artificial utilizada con 10 neuronas en la capa oculta.

El desempeño de los diferentes modelos de red neuronal artificial considerados en este trabajo, se evaluó a través del coeficiente de determinación R^2 y de la raíz cuadrática del error cuadrático medio porcentual ($RMSE\%$), definido como:

$$RMSE\% = \frac{100}{Rad_{med}} \sqrt{\frac{\sum_{i=1}^n (Rad_{est\ i} - Rad_{med\ i})^2}{n}} \quad (1)$$

donde Rad_{med} y Rad_{est} corresponden a la radiación medida y la radiación estimada por los modelos, respectivamente.

4. RESULTADOS

4.1. Caso I: Modelos con diferente número de neuronas en la capa oculta.

Para el Caso I, se consideraron 18 modelos de redes neuronales artificiales diferentes, denominados L_i (con i variando desde 3 hasta 20), donde el subíndice i representa el número de neuronas en la capa oculta de la red neuronal artificial. En todos los casos se tomaron en orden cronológico, los primeros 273 datos para entrenar la red, dejando los últimos 92 datos para validar los modelos.

La Figura 3 presenta los resultados obtenidos del $RMSE\%$ para la totalidad de los modelos $L3$ - $L20$, en donde se puede apreciar que los modelos con menos número de neuronas en la capa oculta poseen un error menor entre los valores de radiación medida y la estimada por los modelos. En particular, el modelo $L8$ es quien posee el mínimo error (aproximadamente un 9%), siendo por

lo tanto ocho el número de neuronas óptimas en la capa oculta de la red neuronal artificial para los datos considerados en este trabajo.




Figura 3 Raíz del error cuadrático medio porcentual para todos los modelos de redes considerados en el Caso I.

El diagrama de dispersión entre la radiación solar medida y la estimada obtenida por el modelo L8, es presentado en la Figura 4, conjuntamente con la recta identidad, la cual permite distinguir que los errores de este modelo son producto principalmente de sobreestimaciones respecto de los valores de radiación solar medidos.




Figura 4 Diagrama de dispersión entre la radiación solar medida y la estimada obtenida por el modelo L8.

4.2. Caso II y Caso III: Modelos con variación en los datos para entrenamiento.

Para el Caso II, se consideraron 6 modelos (M0-M5), todos ellos con 8 neuronas en la capa oculta, los cuales se diferencian entre sí en la manera de tomar los datos para entrenamiento y validación. Los modelos analizados son los presentados en la Tabla 1, donde los datos son denominados de manera similar a la Figura 1. Puede observarse que el modelo M0 coincide con el modelo L8 del Caso I, mientras que el modelo M5 se armó con datos tomados al azar.

Tabla 1 Diseño de los diferentes modelos de redes neuronales considerados en el Caso II.

Modelo	Datos para entrenamiento	Datos para validación
M0 = L8	1-273	274-365
M1	74-346	1-73; 347-365
M2	1-54; 147-365	55-146
M3	1-127; 220-365	128-219
M4	1-200; 293-365	201-292
M5	Aleatorio	Aleatorio

Finalmente, para el Caso III, se consideraron 8 modelos (N0-N7), todos ellos con 8 neuronas en la capa oculta, donde los datos para entrenamiento y validación fueron tomados de la misma manera que el modelo M0, pero se diferencian entre sí en la cantidad de variables de entrada utilizadas en cada modelo, tal como se presenta en la Tabla 2.

Tabla 2 *Diseño de los diferentes modelos de redes neuronales considerados en el Caso III.*

Variables de entrada	Fecha	Prec.	T_Máx.	T_Mín.	Hum.	V_Med	V_Máx	P Atm.
N0 = M0 = L8	✓	✓	✓	✓	✓	✓	✓	✓
N1	✓	✗	✓	✓	✓	✗	✗	✗
N2	✓	✗	✓	✓	✗	✓	✓	✗
N3	✓	✗	✓	✓	✗	✗	✗	✓
N4	✓	✗	✓	✓	✗	✗	✗	✗
N5	✓	✓	✓	✓	✗	✓	✓	✓
N6	✓	✓	✓	✓	✓	✗	✗	✓
N7	✓	✓	✓	✓	✓	✓	✓	✗

La Tabla 3 muestra los valores de R^2 obtenidos en la fase de validación de cada uno de los modelos considerados para los Casos II y III. Puede observarse que existe una gran variación de valores de R^2 , lo cual indica la dependencia de la red neuronal respecto de la elección de los datos para realizar la fase de entrenamiento y de validación.

Tabla 3 *Coefficiente de determinación R^2 de los diferentes modelos de redes neuronales considerados en los Casos II y III.*

Modelos Caso II	R^2	Modelos Caso III	R^2
M0	0.89	N0	0.89
M1	0.59	N1	0.70
M2	0.72	N2	0.67
M3	0.59	N3	0.81
M4	0.64	N4	0.78
M5	0.80	N5	0.64
		N6	0.63
		N7	0.62

5. CONCLUSIONES.

Este trabajo presentó el primer diseño de red neuronal artificial de parte de los autores para la estimación de la radiación solar global diaria en una localidad de la provincia de Córdoba, Argentina. En general, los resultados mostraron un aceptable desempeño de la red neuronal artificial en la estimación de la radiación solar, pero con posibilidades ciertas de ser mejorado. Entre las posibles maneras de mejorar la eficiencia y minimizar los errores de la red neuronal, se tienen: trabajar con mayor cantidad de datos (por lo menos de los últimos 5 años); realizar dos análisis por separado, uno para los meses de alta radiación (desde octubre hasta marzo) y otro para los meses de baja radiación (desde abril hasta septiembre).

6. REFERENCIAS.

- [1] Renewables 2015 Global Status Report (www.ren21.net/wp-content/uploads/2015/.../REN12-GSR2015_Onlinebook_low1.pdf).
- [2] Raichijk, C.; Grossi Gallegos H.; 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*. Vol. 9. Impreso en la Argentina.
- [3] Menges, H. O.; Ertekin, C.; Sonmete, M. H. (2006). "Evaluation of global solar radiation models for Konya, Turkey". *Energy Conversion and Management*. Vol. 47. Páginas 3149–3173.
- [4] Leal, S. S.; Tiba, C.; Piacentini, R. D. (2009). "Modelos estadísticos para determinação da irradiação solar UV diária no estado de Pernambuco". *Avances en Energías Renovables y Medio Ambiente*. Vol. 13. Impreso en la Argentina.
- [5] Kaplanis, S.; Kaplani, E. (2010). "Stochastic prediction of hourly global solar radiation for Patra, Greece". *Applied Energy*. Vol. 87. Páginas 3748–3758.
- [6] Polo Martínez J. (2010). "Optimización de modelos de estimación de la radiación solar a partir de imágenes de satélite". *Tesis Doctoral*. Universidad Complutense de Madrid.

- [7] Priya, S.; Iqbal, M. (2015). "Solar Radiation Prediction using Artificial Neural Network". *International Journal of Computer Applications. Vol. 116*. Páginas 28–31.
- [8] Fadare, D. A.; Irimese, I.; Oni, A. O.; Falana, A. (2010). "Modeling of solar energy potential in Africa using an artificial neural Network". *American Journal of Scientific and Industrial Research. Vol. 1*. Páginas 144–157.
- [9] Mellit, A.; Menghanem, M.; Bendekhis, M. (2005). "Artificial neural network model for prediction solar radiation data: application for sizing stand-alone photovoltaic power system". *IEEE Power Engineering Society General Meeting, 2005*. Páginas 40-44.
- [10] <http://siga2.inta.gov.ar>