



PREDICCIÓN DE LA IRRADIANCIA SOLAR DIARIA MEDIANTE REDES NEURONALES

Morales, D. Martín, Universidad Nacional Arturo Jauretche (UNAJ), Instituto de Ingeniería y Agronomía. Universidad Tecnológica Nacional, Facultad Regional La Plata (UTN, FRLP), Laboratorio de Ingeniería en Sistemas de Información (LINES), martin.morales@unaj.edu.ar

Cappelletti, Marcelo, Universidad Nacional Arturo Jauretche (UNAJ), Instituto de Ingeniería y Agronomía. Universidad Nacional de La Plata (UNLP), Facultad de Ingeniería, Grupo de Estudio de Materiales y Dispositivos Electrónicos (GEMyDE), mcappelletti@unaj.edu.ar

Hasperué, Waldo, Universidad Nacional Arturo Jauretche (UNAJ), Instituto de Ingeniería y Agronomía. Universidad Nacional de La Plata (UNLP), Facultad de Informática, Instituto de Investigación en Informática LIDI (III-LIDI), whasperue@lidi.info.unlp.edu.ar

Charlier, Leandro, Universidad Nacional Arturo Jauretche (UNAJ), Instituto de Ingeniería y Agronomía, leandrocharlier@gmail.com

Resumen— La conversión de energía a través de fuentes de energía renovable y no contaminante se ha tornado un tema trascendente en pos de resolver los problemas de la disminución de los recursos de energía no renovables y la polución ambiental originada por ellos. La radiación solar incidente es la principal fuente de energía renovable disponible en la naturaleza. Su aprovechamiento óptimo requiere de un profundo conocimiento acerca de la irradiancia solar sobre la superficie terrestre, para predecir la producción de energía que podría obtenerse en un determinado lugar. 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 Santiago del Estero, Argentina. Se analizaron diferentes modelos de redes neuronales artificiales capaces de estimar la radiación solar global diaria en dicha localidad. Las redes neuronales permiten crear modelos de predicción pues poseen la capacidad de generalizar y de aprender de patrones de entrada produciendo valores de salida ante la recepción de estímulos similares. 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 clave— *energías renovables, radiación solar, redes neuronales artificiales.*

1. Introducción

La evolución y progreso de la humanidad ha estado ligada sin duda alguna al uso y aprovechamiento de la energía. Al día de hoy, la demanda de energía ha aumentado considerablemente, y se estima que para el año 2030 habrá un 40% más de consumo que en el último año. Por este motivo, la conversión de energía se ha tornado uno de los asuntos más importantes a considerar a nivel mundial.

En la actualidad, aproximadamente el 78% de la demanda final mundial de energía se satisface con sistemas energéticos basados en recursos fósiles no renovables, como el carbón, el gas natural y el petróleo. Poco más del 19% es cubierto con fuentes de energía renovable, mientras que el resto se satisface con energía nuclear [1]. La principal fuente de energía renovable es la biomasa tradicional, utilizada principalmente para cocinar y para calefacción en áreas rurales de países en vías de desarrollo. También existen otras fuentes de energías renovables modernas, 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 (CO₂), dióxido de nitrógeno (NO₂) y metano (CH₄), 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 10.000 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 irradiancia 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 irradiancia 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 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 irradiancia 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 Quimilí, situada en el departamento de Moreno, provincia de Santiago del Estero, 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. 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.

La elección de la localidad de Quimilí para su análisis es debido a que se cuenta con valores experimentales diarios de diferentes variables meteorológicas, incluida la radiación solar global diaria, los cuales han sido obtenidos a través del Sistema de Información y Gestión Agrometeorológico (SIGA) [10].

2. Radiación Solar

El clima, la meteorología y muy especialmente las formas de vida en el planeta son determinados por la energía proveniente del Sol en forma de luz y calor. La radiación solar es la fuente primaria de energía que sustenta la biosfera y el conjunto de procesos físicos, químicos y biológicos que se dan en la Tierra.

El Sol libera energía bajo la forma de radiación electromagnética de alta frecuencia, compuesta de radiaciones de diferentes longitudes de onda, desde el espectro infrarrojo hasta el ultravioleta. Esta energía radiante emitida por el Sol, aproximadamente de 60.000 kW/m^2 , parte en todas las direcciones a la velocidad de la luz. Luego de atravesar el espacio, la radiación que llega a las capas superiores de la atmósfera terrestre es de aproximadamente 1.367 W/m^2 .

Una vez que la radiación solar penetra en la atmósfera, la cantidad de energía que llega directamente a la superficie terrestre se reduce debido a tres fenómenos físicos diferentes: la reflexión, la absorción y la difusión, como se puede apreciar en la Figura 1.



Figura 1. Diferentes tipos de radiación solar.

Del total de radiación solar que llega a la atmósfera terrestre aproximadamente el 35% es reflejada al espacio debido a la presencia de nubes y polvo en la atmósfera, y de elementos como agua, arena, nieve, etc., en la superficie terrestre. Este tipo de radiación se denomina radiación reflejada. Estrictamente, la cantidad de radiación reflejada depende del coeficiente de reflexión de la superficie terrestre, también llamado albedo. Por su parte, aproximadamente el 19% del total de radiación solar que llega a las capas superiores de la atmósfera terrestre es absorbido por el ozono quien elimina las radiaciones ultravioletas nocivas para la salud humana. Finalmente, una parte de la radiación que atraviesa la atmósfera se difunde en todas las direcciones debido a la presencia de moléculas de aire, aerosoles y otras partículas de polvo.

El valor aproximado del flujo medio de energía proveniente del Sol y absorbido por la Tierra (superficie + atmósfera) es de 235 W/m^2 . De ellos, 67 W/m^2 son absorbidos directamente por

los gases y las nubes que componen la atmósfera y los 168 W/m^2 restantes que atraviesan el aire, son absorbidos por la superficie terrestre, repartiéndose de forma muy diferente según la latitud. Este flujo que llega a la superficie terrestre lo hace en forma de radiación directa y difusa. La radiación directa es transmitida directamente desde el Sol hasta el suelo sin sufrir cambio alguno en su dirección. Por su parte, la radiación difusa, es aquella que atraviesa la atmósfera y es reflejada por las nubes o absorbida por éstas. Va en todas direcciones, como consecuencia de las reflexiones y absorciones, no sólo de las nubes sino de las partículas de polvo atmosférico, montañas, árboles, edificios, el propio suelo, etc.

La radiación global o radiación total, es la suma de las radiaciones directa, difusa y reflejada. La proporción de radiación directa y difusa que recibe el suelo depende de la altitud del sol, la absorción de la atmósfera, las nubes, etc. Por ejemplo, en un día despejado, con cielo limpio, la radiación directa es preponderante sobre la radiación difusa. Por el contrario, en un día nublado no existe radiación directa y la totalidad de la radiación que incide es difusa. La atmósfera, entonces, se desempeña como un excelente filtro ya que mediante sus diferentes capas la energía solar es distribuida para que a la superficie terrestre sólo llegue una pequeña parte de la energía total.

La parte externa de la atmósfera absorbe parte de las radiaciones reflejando el resto directamente al espacio exterior, mientras que otras pasarán a la Tierra y luego serán irradiadas. Esto produce el denominado balance térmico, cuyo resultado es el ciclo del equilibrio radiante.

Resumiendo lo mencionado previamente, la distribución del 100% de la energía proveniente del Sol es la siguiente: un 34% regresa al espacio exterior, de forma directa (24%) o indirecta (10%). Un 19% de la energía es absorbida por la atmósfera, mientras que la Tierra recibe un 47% [11]. Ambas serán regresadas al espacio exterior. Esta distribución de la energía hace posible el balance energético en la Tierra.

3. 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 despreciar 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.

3.1 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.

4. 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 Quimilí (Latitud: -27,544; Longitud: -62,352, Altura: 137 metros), situada en el departamento de Moreno, provincia de Santiago del Estero, 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 09/09/2015 y cuenta con los instrumentos necesarios para sensar 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 10/09/2015 hasta el 09/05/2016 inclusive, por lo que se trabajó con 243 vectores de datos.

La Figura 2 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 10/09/2015, Dato 2 el valor observado el 11/09/2015, y así sucesivamente, hasta Dato 243 el valor registrado el 09/05/2016. Se puede observar en dicha figura, que los mayores valores de radiación solar ocurren para los valores centrales, los cuales corresponden a los meses de diciembre y enero.

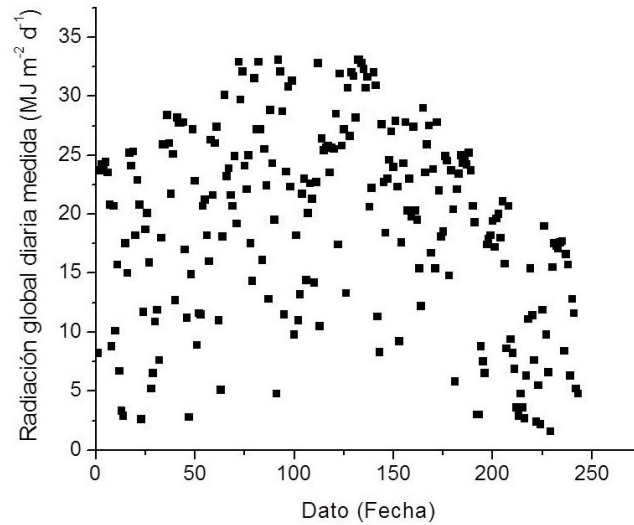


Figura 2. Valores medidos de radiación solar global diaria en el período considerado en este trabajo.

La metodología utilizada para el análisis de los datos presentados en la Figura 2 consistió en tres entrenamientos diferentes de la red neuronal artificial, cada uno de ellos con diferente 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 3 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. En las redes de propagación hacia adelante (feed-forward), todas las señales neuronales se propagan hacia adelante a través de las capas de la red. No existen conexiones hacia atrás ni tampoco autorrecurrentes. En estas redes ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes. Esto se repite hasta obtener un valor en las neuronas de la capa de salida.

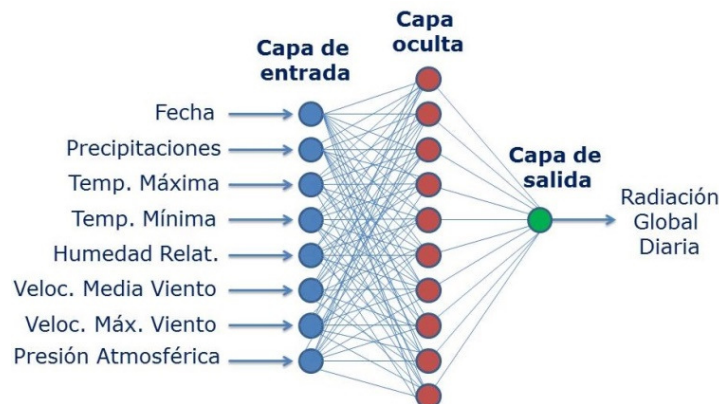


Figura 3. Topología de la red neuronal artificial utilizada con 10 neuronas en la capa oculta.

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.

5. Resultados

En primer lugar, se consideraron 10 modelos de redes neuronales artificiales diferentes, denominados Q_i (con i variando desde 4 hasta 13), 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 182 datos para entrenar la red, dejando los últimos 61 datos para validar los modelos.

La Figura 4 presenta los resultados obtenidos del RMSE% para la totalidad de los modelos Q_4 - Q_{13} , 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 Q_6 es quien posee el mínimo error (aproximadamente un 9%), siendo por lo tanto seis el número de neuronas óptimas en la capa oculta de la red neuronal artificial para los datos considerados en este trabajo.




Figura 4. Raíz del error cuadrático medio porcentual para los modelos de redes Q_i .

El diagrama de dispersión entre la radiación solar medida y la estimada obtenida por el modelo Q_6 , es presentado en la Figura 5, 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.

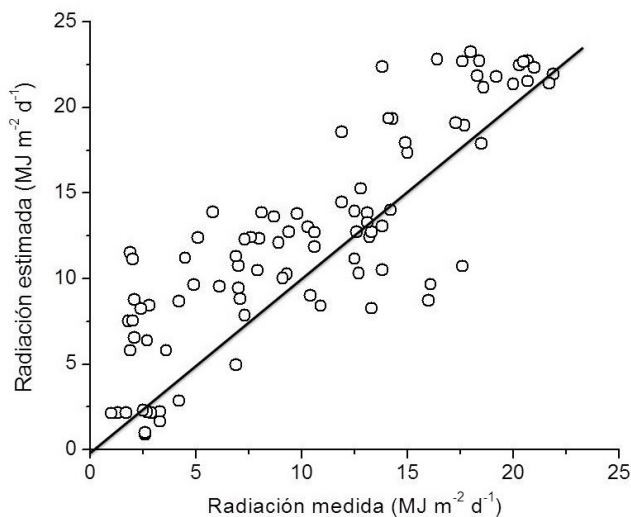


Figura 5. Diagrama de dispersión entre la radiación solar medida y la estimada obtenida por el modelo Q_6 . El valor del RMSE para este modelo es de 9% aproximadamente.

A continuación, se consideraron cuatro modelos (R_0 - R_3), todos ellos con 6 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 R_0 coincide con el modelo Q_6 , mientras que el modelo R_3 se armó con datos tomados al azar. La Tabla 1 muestra además los valores del coeficiente de determinación R^2 obtenidos en la fase de validación de cada uno de los modelos considerados. 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 1. Diseño de los modelos de redes neuronales R_0 - R_3 .

Modelo	Datos para entrenamiento	Datos para validación	Coficiente de determinación R^2
$R_0 = Q_6$	1-182	183-243	0.77
R_1	62-243	1-61	0.62
R_2	1-90; 152-243	91-151	0.83
R_3	Aleatorio	Aleatorio	0.72

6. Conclusiones

El 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 Santiago del

Estero, 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 cinco 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).

7. 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.; IRIMISOSE, 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>
- [11] RAMOS CASTELLANOS, P. (2008). “Energías y cambio climático”. *XII Jornadas Ambientales*. Universidad de Salamanca. 416 páginas.