



Scientia Et Technica

ISSN: 0122-1701

scientia@utp.edu.co

Universidad Tecnológica de Pereira
Colombia

Triviño Castañeda, Valentina; Escobar Mejía, Andrés; Valdés, Henry Giovanny

Estimación de Radiación Solar Para el Cálculo de la Confiabilidad
de Sistemas Fotovoltaicos Usando Redes Neuronales

Scientia Et Technica, vol. 23, núm. 1, 2018, Enero-Marzo, pp. 11-18

Universidad Tecnológica de Pereira
Colombia

DOI: <https://doi.org/10.22517/23447214.16481>

Disponible en: <https://www.redalyc.org/articulo.oa?id=84956661008>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en [redalyc.org](https://www.redalyc.org)

redalyc.org
UAEM

Sistema de Información Científica Redalyc
Red de Revistas Científicas de América Latina y el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso
abierto

Estimación de Radiación Solar Para el Cargo por Confiabilidad de Sistemas Fotovoltaicos Usando Redes Neuronales

Artificial Neural Networks Applicable to Estimate Solar Radiation to Calculate the Reliability Charge in Photovoltaic Plants

Valentina Triviño Castañeda¹, Andrés Escobar Mejía², Henry Giovanny Valdés³

^{1,2}Facultad de Ingenierías, Universidad Tecnológica de Pereira, Pereira, Colombia.

³Gerencia Administrativa y Financiera, Empresa de Energía de Pereira, Colombia.

valenct@utp.edu.co

andreses1@utp.edu.co

hvaldes@eep.com.co

Resumen—La Comisión de Energía y Gas (CREG) estableció a finales del 2016 una metodología para el cálculo del Cargo por Confiabilidad de plantas solares fotovoltaicas. En esta se establece que se requieren series históricas de más de diez años de irradiación solar y temperatura ambiente en el sitio de instalación de la planta para el cálculo de dicho cargo, sin embargo, en Colombia no se cuenta con datos históricos con dicha información, por lo que se requiere de estrategias que permitan la estimación de dichas series a partir de otras variables de entrada. El presente artículo emplea Redes Neuronales Artificiales para estimar datos de radicación solar requeridos utilizando como datos de entrada la humedad relativa, temperatura ambiente y mes del año.

Palabras clave— Cargo por Confiabilidad, Energía Firme, Plantas Solares Fotovoltaicas, Redes Neuronales Artificiales.

Abstract—The Comisión de Energía y Gas (CREG) published in 2016 the guidelines to calculate the reliability charge for solar plants. The methodology indicates that in order to calculate the base load power for the reliability charge, it is required ten years of information with solar radiation and ambient temperature. In Colombia there is not such information, thus it is required to use strategies to estimate the required information from available data. In this paper Artificial Neural Networks are used to estimate solar radiation considering ambient temperature, relative humidity and month of the year.

Key Word — Artificial Neural Networks, Base Load Power Reliability Charge, Photovoltaic Systems.

I. INTRODUCCIÓN

Actualmente la energía eléctrica en Colombia es producida principalmente por centrales hidroeléctricas (70%), plantas termoeléctricas (13%) —gracias a la disponibilidad de gas

natural—, plantas que emplean carbón y ACPM (13%), y en una menor proporción (4%), a partir de otras fuentes de generación como plantas eólicas, biomasa, etc [1]. A pesar de la puesta en marcha de nuevos proyectos hidroeléctricos y térmicos para aumentar la capacidad de generación y cubrir la demanda, las energías renovables, como la energía geotérmica, eólica, biomasa, solar y térmica, presentan un panorama promisorio a largo plazo y se consideran como nichos de oportunidad que le aportarían grandes beneficios al país. Factores como el interés por diversificar la matriz energética, reducir las emisiones de gases de efecto invernadero a la atmósfera y el compromiso por tener una red eléctrica mucho más sostenible y segura, han incentivado en Colombia la exploración de nuevas fuentes de generación como las Fuentes No Convencionales de Energía (FNCE) [2].

Dentro del portafolio de las FNCE, la energía solar fotovoltaica aparece como una de las alternativas que ha tenido mayores niveles penetración en los sistemas eléctricos. Ya para el año 2013 se contaba a nivel mundial con una capacidad instalada de 139 GW [2], lo que representa entre el 0.85% y 1% de la capacidad total instalada. Este crecimiento se ha logrado principalmente gracias a la creación de nuevas reglamentaciones que buscan reducir el uso de centrales generadoras que emplean combustibles fósiles para la generación de energía. Otras estrategias como tarifas garantizadas o *Feed-In Tariff* (FIT), subastas, certificados de energía renovable, contratos por diferencias, medición bidireccional, entre otros, han sido también relevantes para impulsar las FNCE.

El Congreso de la República de Colombia por medio de la ley 1715 de 2014 ha pretendido promover el desarrollo y utilización de las FNCE en el sistema energético nacional.

También en dicha reglamentación se han establecido lineamientos que facilitan su participación en el mercado eléctrico, con el fin de garantizar el abastecimiento energético, diversificar la matriz energética, afrontar los ya recurrentes cambios climáticos (fenómeno del Niño y la Niña), y lograr un desarrollo económico sostenible de las regiones no interconectadas [3]. Actualmente se ha podido establecer que el país cuenta con una irradiación promedio de 4.5 kWh/m²/d [2], [4] la cual supera el promedio mundial de 3.9 kWh/m²/d, y está muy por encima del promedio recibido en países como Alemania (3.0 kWh/m²/d) [2], que es el país que hace mayor uso de la energía solar fotovoltaica a nivel mundial con aproximadamente 36 GW de capacidad instalada a 2013 [2]. En buen parte de la Costa Atlántica, departamentos como Arauca, Casanare, Vichada y Meta, los niveles de irradiación pueden llegar a valores máximos de 6.0 kWh/m²/d [5]. Estos datos muestran como en Colombia este tipo de generación se proyecta como una gran oportunidad no solo para la reducción de emisiones de gases de efecto invernadero sino también para dar soluciones energéticas al país en el largo plazo.

En el sector eléctrico colombiano se cuenta con el denominado Cargo por Confiabilidad, que entre otros, remunera a generadores por tener disponibilidad de producir Energía Firme durante condiciones críticas de abastecimiento. Debido a la naturaleza fluctuante e intermitente de las FNCE, este cargo debe de ser definido de acuerdo a la particularidad de cada recurso. Para plantas eólicas la metodología para el Cargo por Confiabilidad es definida en [6] y modificada en [7]. Para plantas solares fotovoltaicas, se presenta inicialmente un proyecto de metodología en [8] para discusión, siendo completamente establecido en [9]. Dicha metodología establece que para determinar la Energía Firme para el Cargo por Confiabilidad (ENFICC) se debe contar (además de otras constantes que son función del sistema solar fotovoltaico instalado) con una serie histórica que contenga registros de irradiación solar horizontal y temperatura ambiente de mínimo diez (10) años medidas en el sitio de instalación de la planta [5]. En Colombia no existe una base de datos con dicha información, por lo que el Consejo Nacional de Operaciones (CNO) ha sugerido que se consideren las mediciones realizadas durante un año.

Al no contar con dicha información, se debe realizar un dictamen técnico para desarrollar la estimación de las series históricas, con base en mediciones en el sitio de la planta y registros de otros puntos de medición para cada hora [5].

El presente trabajo de investigación presenta una metodología que emplea Redes Neuronales Artificiales o *Artificial Neural Networks* (ANN) –útiles en la estimación de parámetros– con el fin de estimar las series de irradiación solar requeridas para realizar el Dictamen Técnico descrito en [9] para determinar la Energía Firme para el ENFICC. Como parámetros de entrada a la red se utilizan la temperatura ambiente, la humedad relativa y el mes del año registrados por el Aeropuerto Internacional Matecaña de la ciudad de Pereira y

la Universidad Tecnológica de Pereira y que pueden ser encontrados en [10], [11].

El artículo desarrolla la metodología propuesta en las siguientes secciones: En la sección II se presenta el cálculo de la ENFICC para plantas solares fotovoltaicas. La aplicación de las ANN a la estimación de la energía solar es descrita en la sección III. La sección IV presenta el caso de estudio. El análisis estadístico realizado a los datos obtenidos es descrito en la sección V. En la sección VI se realiza la validación de la red neuronal a través de la estimación de datos futuros de irradiación empleando una base de datos conocida. Finalmente, las conclusiones del artículo son presentadas en la sección VII.

II. CÁLCULO DE LA ENFICC PARA SISTEMAS SOLARES FOTOVOLTAICOS

La Resolución 243 de 2016 establece que para el cálculo de la ENFICC de plantas solares fotovoltaicas se debe contar con información horaria de irradiación solar horizontal y temperatura ambiente de mínimo diez (10) años, medida en el sitio de la planta [9]. La energía generada en el mes m del año t por una planta solar fotovoltaica en kWh/mes se calcula como:

$$EN_{m,t} = \frac{1}{I_{STC}} K_c * K_{inc} * V_{m,t}(TA_{m,t}) * GHI_{m,t} * (1 - IHF) * POT_{dc}, \quad (1)$$

donde:

I_{STC} :	Irradiación en condiciones constantes. $I_{STC} = 1 \text{ kW/m}^2$.
K_c :	Constante por pérdidas de un sistema solar fotovoltaico. $K_c = 0,9139$.
K_{inc} :	Constante de inclinación que depende del tipo de tecnología de estructura de soporte.
$V_{m,t}(TA)$:	Valor por pérdidas debidas a temperatura ambiente según el tipo de modulo fotovoltaico utilizado del mes m del año t en °C.
$TA_{m,t}$:	Promedio de temperatura ambiente para cada mes m del año t en °C.
$GHI_{m,t}$:	Irradiación horizontal agregada para el mes m del año t en kWh-mes/m ² .
IHF :	Indisponibilidad histórica forzada que se obtienen según la regulación vigente para plantas térmicas.
POT_{dc} :	Potencia del conjunto de módulos fotovoltaicos, kW pico.

Para el cálculo de EN sólo se tendrán en cuenta los datos de irradiación horizontal y de temperatura ambiente para aquellas horas del día en las cuales se tengan datos de irradiación horizontal diferente a cero. Los valores correspondientes a constante K_{inc} se presentan en la Tabla I.

Las pérdidas por temperatura ambiente, $V_{m,t}(TA_{m,t})$, se determinan como:

$$V_{m,t}(TA_{m,t}) = 1 - [a * (TA)^3 + b * (TA)^2 + c * TA + d], \quad (2)$$

en donde los valores de las constantes a, b, c y d se presentan en la Tabla II, de acuerdo con la tecnología: Silicio (cSi), Thin Film (TF), y el tipo de estructura (fija, 1 y 2 ejes).

Ahora bien, la energía E_n del n -esimo dato en kWh/día se calcula de acuerdo con:

$$E_n = \frac{EN_{m,t}}{Días_m}, \quad (3)$$

en donde $EN_{m,t}$ es el valor de energía del mes (m) del año t de la serie histórica, correspondiente al valor mencionado anteriormente. Con los valores E_n para toda la serie histórica, correspondiente al procedimiento definido anteriormente, se construye una curva de distribución de probabilidad ordenando los resultados de menor a mayor. El menor valor corresponderá al 100% de Probabilidad de Ser Superado (PSS) y el mayor valor corresponderá al 0% de PSS. El ENFICC para la planta se calcula obteniendo el ENFICC base y el ENFIC 95% PSS [9]. El primero corresponde a aquella generación que es capaz de entregar la planta en la condición del 100% de PSS. El segundo corresponde a aquella generación que es capaz de entregar la planta en la condición del 95% PSS de la curva de distribución de probabilidades.

TABLA I. CONSTANTE K_{inc} PARA DIFERENTES ESTRUCTURAS

TECNOLOGÍA DE ESTRUCTURA DE SOPORTE	K_{inc}
Estructura fija orientada al SUR e inclinada en su grado óptimo.	0,9620
Estructura de seguidor a un eje horizontal Norte-Sur y rotación Este- Oeste con backtracking.	1,1861
Estructura de seguidor a un eje inclinado Norte-Sur y rotación Este- Oeste con backtracking.	1,1958
Estructura de seguidor a dos ejes sin backtracking.	1,2530

TABLA II. CONSTANTES PARA HALLAR $V_{m,t}(TA_{m,t})$

TIPO MÓDULO Y ESTRUCTURA	$ax10^{-5}$	$bx10^{-4}$	$cx10^{-2}$	$dx10^{-1}$
Fija - cSi	3,8	-24	5,22	-3,121
Fija - TF	2,6	-17	3,73	-2,126
1 eje - cSi plano	1,1	-7	1,85	-1,157
1 eje - cSi inclinado	1,1	-7	1,85	-0,115
1 eje - TF plano	-1,3	7	-0,92	0,501
1 eje - TF inclinado	-1,3	74	-0,92	0,501
2 ejes - cSi	3,7	-2	1,03	-0,615

Se tiene entonces que el ENFICC base o el ENFIC 95% PSS en kWh/día para el año t se calculan como:

$$ENFICC_t = ENFICC_{BASE,95\%PSS} * K_{med,t}, \quad (4)$$

de donde $K_{med,t}$ es el factor de degradación que depende del lugar y año donde se realicen las mediciones [9].

III. APLICACIÓN DE LAS REDES NEURONALES A LA ESTIMACIÓN DE IRRADIACIÓN SOLAR

Las ANN se pueden definir como un conjunto de técnicas perteneciente al campo de la inteligencia artificial que cuentan con una estructura de red formada por nodos (neuronas) conectadas entre sí. Dichas redes son ampliamente utilizadas en reconocimiento de patrones, aproximación de funciones y predicción de variables en teoría de control [12]. Las ANN aprenden por ejemplos asignados por un grupo de datos de entrenamiento. Después de que la red está entrenada, es capaz de responder ante cualquier valor de entrada para el cual no fue preparada, prediciendo su respuesta de acuerdo a patrones reconocidos y guardados en sus pesos (ω) y bias (b).

Existen diversas estructuras y formas de entrenamiento para las ANN y depende del programador definir el número de capas ocultas, funciones de transferencia, número de neuronas, funciones de entrenamiento, etc. En la figura 1 se presenta un esquema general de la estructura de la ANN [13] en donde se puede observar que los datos de entrada (x), inicialmente son multiplicados por sus respectivos pesos (ω), para luego ser adicionados a la función de propagación o función de red. La salida es después aplicada a la función de activación, arrojando un error en la predicción de variables. Después de realizar cada iteración se compara el error y el criterio de parada para terminar el entrenamiento.

Diferentes estudios han mostrado la utilidad de las ANN en la estimación de la irradiación solar. En [14] se realizó la predicción en Bogotá a partir de datos de entrada que comprendían mediciones de irradiación durante siete años.

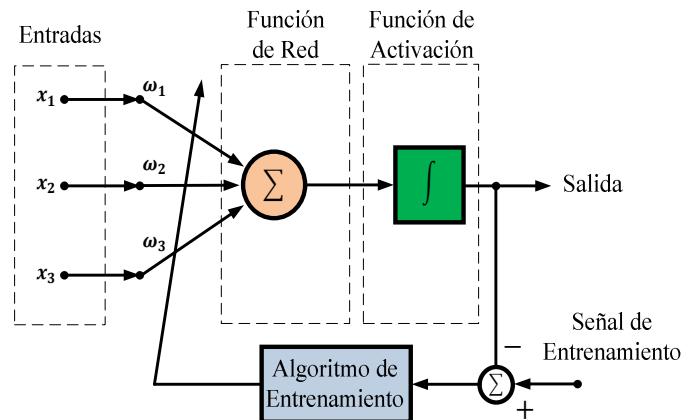


Figura 1. Estructura de una red neuronal artificial.

En [15] se presenta una metodología, basada en ANN, que presentó mínimo error en la estimación de la irradiación solar difusa en Zhengzhou, China. En [16] se presenta un estudio que describe modelos autorregresivos multiplicativos para generar series de irradiación global con intervalos de tiempo de cinco minutos.

En [17] se realizó la predicción de irradiación solar para la ciudad de Dezful, Iran, usando tres combinaciones de conjuntos de datos para obtener la irradiación solar global: a) la duración del día, la temperatura media diaria del aire y la humedad relativa, b) la duración del día, la temperatura media diaria del aire y las horas de brillo del sol en el día, y finalmente, c) la duración del día, la temperatura media diaria del aire, humedad relativa y las horas de brillo del sol.

Otros estudios como en [18] y [19] han mostrado la ventaja de utilizar ANN en la estimación de variables como temperatura ambiente y humedad relativa, e irradiación solar respectivamente. Lo anterior indica la utilidad de dicha estrategia en la estimación de variables, ya que brinda la facilidad de adaptarse a funciones complejas con el fin de extrapolar valores por medio de un sistema de interconexiones dinámicas y paralelas, con lo que se logra reducir el tiempo de convergencia cuando es comparada con otros métodos.

IV. APLICACIÓN AL CASO DE ESTUDIO

Tres topologías de ANN son estudiadas con el fin de elegir aquella que arroje menor error y poder estimar la serie histórica de irradiación solar requerida para el cálculo de la ENFICC. Las topologías difieren según el número de neuronas, el número de capas ocultas y la función de transferencia como se indica en la Tabla III. El conjunto de entrenamiento de la red neuronal corresponde a los datos de irradiación disponibles en [11].

TABLA III. DATOS USADOS SEGÚN LA TOPOLOGÍA

ITEM	TOPOLOGÍA 1	TOPOLOGÍA 2	TOPOLOGÍA 3
Neuronas por Capa	Capa uno: 10 Capa dos: 1	Capa uno: 7 Capa dos: 3 Capa tres: 1	Capa uno: 7 Capa dos: 3
Función de Entrenamiento	Gradiente descendiente por grupo (TRAINGD)	Gradiente descendiente por grupo con momento (TRAINGDM)	Levenberg-Marquardt (TRAINLM)
Función de Adaptación de Aprendizaje	LEARNGD	LEARNGDM	LEARNGM
Función de Desempeño	MSE		
Funciones de Transferencia	TANSIG PURELIN	LOGSIG TANSIG PURELIN	LOGSIG PURELIN
Épocas	1.000	1.000	1.000

Una vez entrenada la red se usan como variables de entrada al sistema los datos de temperatura ambiente y humedad relativa disponibles en [10], al igual que el mes del año. Se trabaja con estas variables basados en los estudios realizados previamente en [18], [17], en donde se demuestra la dependencia y correlación de la irradiación solar con cada una de las variables descritas. Los datos de entrada son normalizados teniendo en cuenta los rangos de valores utilizados en la Tabla IV. Se implementan las tres topologías buscando el menor error en la estimación. Los resultados del entrenamiento son presentados en las figuras 2, 3 y 4 donde se indica el Error Cuadrático Medio o *Mean Square Error* (MSE), en dichas figuras se ilustra hasta la época de convergencia de cada topología.

TABLA IV. VALORES MÍNIMOS Y MÁXIMOS DE LAS VARIABLES

VARIABLE	MÍNIMO	MÁXIMO	RELACIÓN
Humedad (%)	59,60	94,12	$H = \frac{humedad - 59,6}{94,12 - 59,6}$
Temperatura (°C)	16,33	24,46	$T = \frac{temperatura - 16,33}{24,46 - 16,33}$
Mes	1	9	$M = \frac{mes}{9}$

BEST VALIDATION PERFORMANCE IS 0,012402 AT EPOCH 91

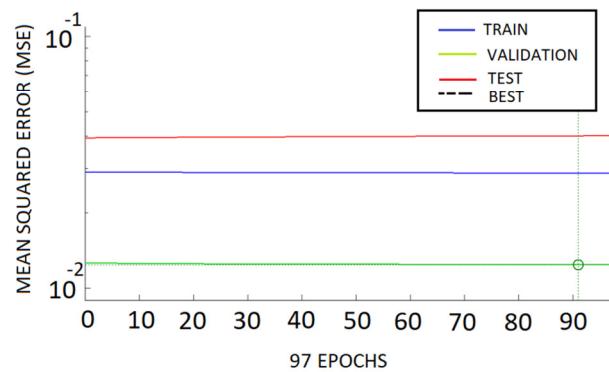


Figura 2. Representación de la evolución de los errores en la topología uno con MSE=1,24%.

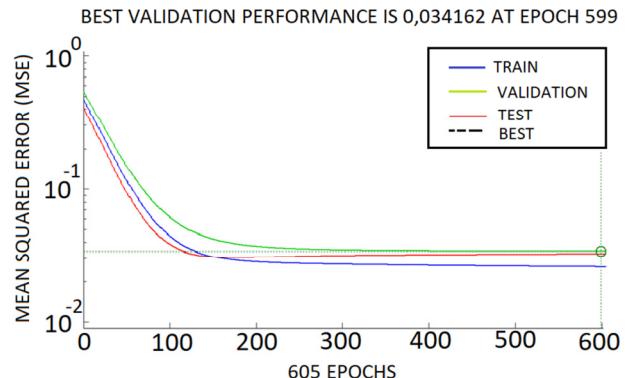


Figura 3. Representación de la evolución de los errores en la topología dos con MSE=3,41%.

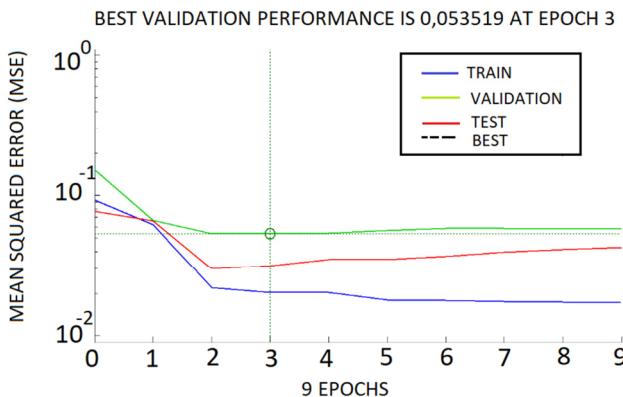


Figura 4. Representación de la evolución de los errores en la topología tres con MSE=5,35%.

Después de entrenar la red y seleccionando la topología uno para la estimación, se ingresan los valores de temperatura ambiente, humedad relativa y mes del año de la base de datos disponible en [10] (de 2000 a 2010) para la estimación de la irradiación solar. Con los datos históricos obtenidos, es posible determinar la ENFICC.

Debido a que los datos de entrada a la ANN son valores normalizados, es necesaria la desnormalización con el fin de obtener los valores reales de irradiación solar, teniendo en cuenta los mismos rangos usados para la normalización. En la figura 5 se puede observar los resultados de la estimación de irradiación solar para cada año y mes, durante diez años, empleando datos de temperatura, humedad relativa y mes del año para la estimación.

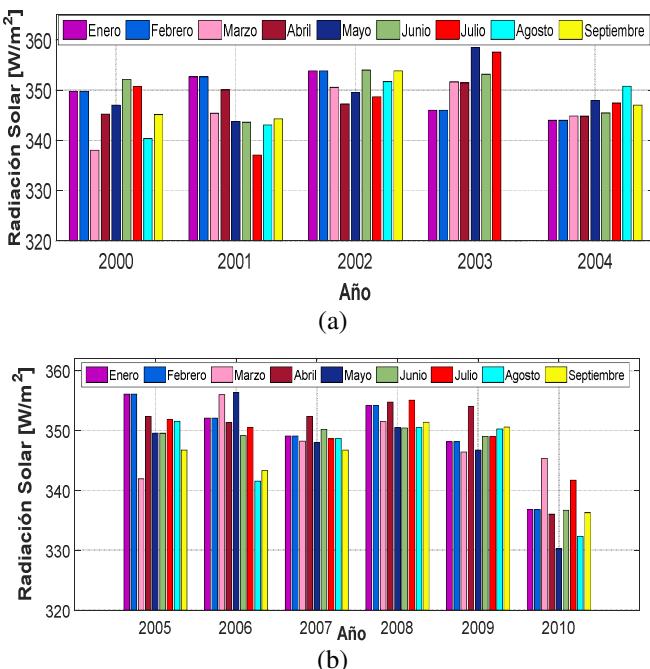


Figura 5. Estimación de irradiación solar utilizando la topología uno para los años 2000-2004 (a) y 2005-2010 (b).

V. ANÁLISIS ESTADÍSTICO DE RESULTADOS

Para el cálculo de $V_{m,t}(TA_{m,t})$ según (2), se emplea una estructura Fija c-Si (según Tabla II). Para $K_{inc}=0,962$, $K_c=0,8957$ y $POT_{dc}=20$ kW pico, $EN_{m,t}$ es calculada como se presenta en (1). La IHF se toma según la resolución vigente para plantas térmicas, en este caso es de 0,2 según la resolución CREG 071 de 2006. Siguiendo este procedimiento paso a paso se construye la base de datos de $EN_{m,t}$.

Después de tener los datos $EN_{m,t}$ de toda la serie histórica se procede a ordenarlos de menor a mayor. El menor valor corresponderá al 100% de la PSS y el mayor valor será el 0% de la PSS. Para obtener el 95% de la PSS se emplean dos procedimientos: Análisis de datos y frecuencias y el área bajo la curva de distribución de probabilidad [20].

Para poder declarar ENFICC se debe obtener el 95% de la PSS de la curva de probabilidad, para ello se debe primero comprobar si la distribución es normal, con una prueba de bondad y ajuste. Después de realizada esta prueba se determina que los datos de energía hallados no sigan un modelo de distribución normal, por lo cual se realiza una transformación no lineal con los datos. La figura 6 muestra los datos de energía agrupados en clases, cuyos valores vienen definidos por una distribución simétrica, dando como resultado la frecuencia de los datos en cada una de las clases. Procesando los datos del histograma obtenido, se encuentra la curva de distribución de probabilidades que se muestra en la figura 7, la cual es utilizada para encontrar el 95% PSS. Para obtener el área bajo la curva que corresponde al 95% del área total, se realiza la siguiente normalización:

$$Z = \frac{X - \mu}{\sigma} \quad (5)$$

Luego se busca en la tabla de distribuciones normalizadas encontradas [20], el valor de Z y se despeja de (5) el valor de X que corresponde a la irradiación de 95% PSS. En la Tabla V se listan los valores de ENFICC a declarar.

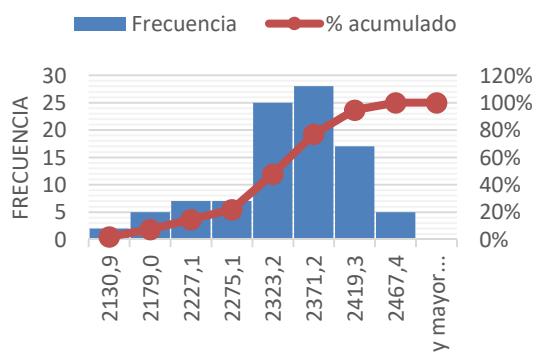


Figura 6. Histograma para establecer la curva de distribución de probabilidad.

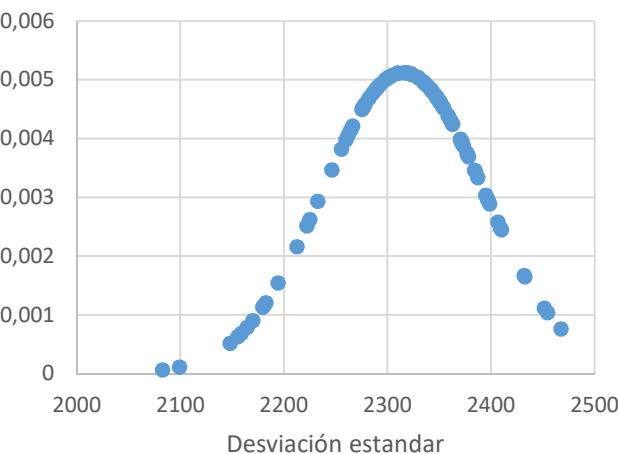


Figura 7. Curva de distribución de probabilidad con el cambio de variable.

TABLA V. VALORES DE ENFICC ENCONTRADOS

ENFICC BASE (kW-h/día)	45,6387
ENFICC 95% PSS (kW-h/día)	46,7652

VI. VALIDACIÓN DE LA RED NEURONAL

Con el fin de validar la topología seleccionada en la estimación de parámetros, se emplea la base de datos de irradiación solar disponible en [21]. De la misma se seleccionan 26 días para la validación. Los trece primeros días son utilizados como conjunto de entrenamiento de la red, mientras que los restantes son usados para validación. La tabla VI presenta la estimación de la radicación con sus respectivos errores.

TABLA VI. RESULTADOS DE LA VALIDACIÓN DE DATOS

Irradiación Aproximada [W/m ²]	Irradiación Real [W/m ²]	Error (%)
260,57	161,49	61,35
419,21	507,02	17,32
338,42	303,21	11,61
330,10	215,19	53,40
310,69	382,99	18,88
326,09	316,79	2,94
280,99	215,41	30,44
332,87	475,09	29,94
461,28	460,34	0,20
457,03	471,36	3,04
299,70	267,59	12,00
300,62	331,27	9,25
354,66	215,09	64,89

VII. CONCLUSIONES

Basados en los datos de energía obtenidos en este estudio, en una estación ubicada en Pereira se puede declarar una ENFICC BASE de 45,6387 kw-h/día y una ENFICC 95% PSS de 46,7652 kw-h/día bajo las condiciones especificadas.

Se debe realizar la prueba de bondad de ajuste para determinar si la distribución efectivamente se adopta a una distribución normal, ya que se pueden generar errores si se declara ENFICC sin comprobar su modelo de distribución.

El error arrojado por la ANN se reduce del 10% al 1,24% al ingresar las variables de entrada de manera aleatoria, es decir, combinando los datos de todos los meses y no ingresando los mismos de manera consecutiva.

Si bien la validación de la topología seleccionada empleando los datos de irradiación disponibles en [21] presenta en algunos casos errores superiores al 50%, se puede concluir que la estimación de la irradiación solar presentada en la figura 5 empleando la topología uno, es adecuada considerando que solo se cuenta con datos de trece días para el entrenamiento. La inexistencia de bases datos con la información requerida para el cálculo de la ENFIC, demanda la utilización de técnicas de estimación que emplean variables que estén correlacionadas con la irradiación solar.

Se concluye que una manera adecuada para tomar los datos en sitio es hacer mediciones cada hora durante un año. Esto se debe a que la Red Neuronal Artificial queda mejor entrenada (menor error) si se toman y adoptan valores de todos los meses del año. Dicho periodo de recolección de información se recomienda basado en el análisis de los datos observados en la estación de medición de la Universidad Tecnológica de Pereira y en las recomendaciones hechas en [1].

AGRADECIMIENTOS

Los autores agradecen al área de gerencia administrativa y financiera de las Empresas de Energía de Pereira S.A. ESP por su constante apoyo durante la realización de este trabajo. También se agradece al *Sustainable Smart Electrical Energy Systems Research Group* de *University of Arkansas* por los datos de irradiación solar para la validación de la red.

REFERENCIAS

- [1] SIMEC, “Informe Mensual de Variables de Generación Mercado Eléctrico Colombiano, diciembre de 2016,” [Online]. Consultado: 22/03/2018. Available: http://www.siel.gov.co/portals/0/generacion/2016/Segui_variables_dic_2016.pdf.

- [2] UPME. “Integración de las energías renovables no convencionales en Colombia,” 2015. [Online]. Consultado: 22/03/2018. Available: http://www.upme.gov.co/Estudios/2015/Integracion_Energias_Renovables/INTEGRACION_ENERGIAS_RENOVABLES_WEB.pdf
- [3] Ley 1715, 2014. “Por medio de la cual se regula la integración de las energías renovables no convencionales al sistema energético nacional”. [Online]. Consultado: 23/03/2018. Available: http://www.upme.gov.co/Normatividad/Nacional/2014/LEY_1715_2014.pdf.
- [4] IDEAM “Atlas de Radiación Solar, Ultravioleta y Ozono de Colombia,” [Online]. Consultado: 22/03/2018. Available: <http://atlas.ideam.gov.co/visorAtlasRadiacion.html>.
- [5] Superintendencia de Servicios Públicos, Comité de Seguimiento del Mercado Mayorista de Energía Eléctrica, “Competitividad de la Energía Eólica y Solar en el Mercado de Energía Mayorista,” Junio, 2016.
- [6] CREG, Resolución 148 de 2011, “Por la cual se define la metodología para determinar la energía firme de plantas eólicas,” [Online]. Consultado: 22/03/2018. Available: http://servicios.minminas.gov.co/compilacionnormativa/docs/resolucion_creg_0148_2011.htm
- [7] CREG, Resolución 061 de 2015, “Por la cual se modifica la metodología para determinar la energía firme de plantas eólicas,” [Online]. Consultado: 23/03/2018. Available: [http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/a4170681d70b32f905257e4a006d8d5a/\\$FILE/Creg061-2015.pdf](http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/a4170681d70b32f905257e4a006d8d5a/$FILE/Creg061-2015.pdf).
- [8] CREG, Proyecto de Resolución 227 de 2015, “Por la cual se define la metodología para determinar la energía firme de plantas solares fotovoltaicas,” [Online]. Consultado: 22/03/2018. Available: [http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/59aa7fe361aca6c405257f39007956fe/\\$FILE/Creg227-2015.pdf](http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/59aa7fe361aca6c405257f39007956fe/$FILE/Creg227-2015.pdf).
- [9] CREG, Resolución 243 de 2016, “Por la cual se define la metodología para determinar la energía firme para el cargo por confiabilidad, ENFICC, de plantas solares fotovoltaicas,” [Online]. Consultado: 23/03/2018. Available: [http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/82606579833fa7d3052580c0004f7b6a/\\$FILE/Creg243-2016.pdf](http://apolo.creg.gov.co/Publicac.nsf/1c09d18d2d5ffb5b05256eee00709c02/82606579833fa7d3052580c0004f7b6a/$FILE/Creg243-2016.pdf).
- [10] Clima Pereira / Matecaña”. [Online]. Consultado: 22/03/2018. Available: http://www.tutiempo.net/clima/Pereira_Matecaña/01-2016/802100.htm.
- [11] Red Hidroclimatológica, “Clima Pereira/Matecaña”. [Online]. Consultado: 23/03/2018. Available: <http://redhidro.org/home/>.
- [12] F.N. Chowdhury, P. Wahi, R. Raina, S. Kaminerdi, “A survey of neural networks applications in automatic control,” in *proc. of the 33rd Southeastern Symposium on System Theory*, Athens, OH, pp. 349–353, 2001.
- [13] M. Hassoun, *Fundamentals of Artificial Neural Networks*, MIT Press, 2003.
- [14] R. Perdomo, E. Banguero, G. Gordillo, “Statistical modeling for global solar radiation forecasting in Bogotá,” in *Proceedings of the 35th IEEE Photovoltaic Specialists Conference*, (PVSC), pp. 1–6, June, 2010.
- [15] Y. Jiang, “Estimation of monthly mean hourly diffuse solar radiation,” in *Proceedings of the World Non-Grid-Connected Wind Power and Energy Conference*, pp. 1–4, September, 2009.
- [16] A. Moreno-Munoz, J.J.G. de la Rosa, R. Posadillo, F. Bellido, “Very short term forecasting of solar radiation,” in *Proc. of the 33rd IEEE Conference on Photovoltaic Specialists*, San Diego, CA, USA, pp. 1–5, May, 2008.
- [17] A. Ghanbarzadeh, A.R. Noghrehabadi, E. Assareh and M. A. Behrang, “Solar radiation forecasting based on meteorological data using artificial neural networks,” in *Proceedings of the 7th IEEE International Conference on Industrial Informatics*, Cardiff, Wales, pp. 227–231, June, 2009.
- [18] L.A. Rosario, E.J. Pereyra M., J.C. Vielma S., “Estimación de temperatura y humedad relativa en Venezuela mediante redes neuronales”. [Online]. Consultado: 22/03/2018. Available: <http://erevistas.saber.ula.ve/index.php/cienciaeingenieria/article/viewFile/405/420>.
- [19] A.D. Orjuela-Cañón, J. Hernández, C.R. Rivero, “Very short term forecasting in global solar irradiance using linear and nonlinear models,” in *Proc. of the IEEE Workshop on Power Electronics and Power Quality Applications*, (PEPQA), Bogota, pp. 1–5, July, 2017.
- [20] L. Marchal Wathen, *Estadística aplicada a los negocios y la economía*. Décimo sexta edición, 2015, MCGRAW-HILL.
- [21] A. Barnes, J. Hayes, J.C. Balda, A. Escobar, “PV Data,” [Online]. Consultado: 23/03/2018. Available: <https://sustainable-energy.uark.edu/pv/>