

Comparación metodológica para pronosticar capacidad de generación de energía fotovoltaica basado en datos climáticos

Methodological comparison to predict photovoltaic generation capacity based on climatic data

E.Obando-Paredes^{1,2}, SX Carvajal-Quintero¹, J. Pineda¹

¹ Environmental, Energy and Education Policy - E3P, Universidad Nacional –Sede Manizales, Colombia Email: {edobandop, sxcarvajalq, jpinedaa}@unal.edu.co

² Grupo de Investigación ESLINGA Universidad Cooperativa de Colombia –Sede Pasto Email: ²edgar.obandop@campusucc.edu.co

RECIBIDO: abril 21, 2017. ACEPTADO: junio 02, 2017. VERSIÓN FINAL: noviembre 01, 2017

RESUMEN

El presente artículo está enfocado en comparar diferentes técnicas de predicción para el pronóstico de capacidad de generación de potencia fotovoltaica bajo técnicas de aprendizaje automático. En primer lugar se identifica la relación entre variables climáticas, de las cuales depende directamente la generación solar. Para después con el uso de una base de datos meteorológica de amplio recorrido (NSBD de NREL), proveer los datos climáticos de entrada a los algoritmos implementados cuya respuesta será comparada en un caso particular de generación de potencia fotovoltaica, en la ciudad de Popayán en uno de los meses de más alta radiación. Se implementan dos algoritmos, el primero basado en un clasificador Bayes-Naive sin ningún tipo de combinación y el segundo un tipo de Red Neuronal combinado con un algoritmo de optimización Levenberg-Marquardt. Presentando mejor desempeño este último sin la implementación de una etapa de pre procesamiento de los datos de entrada en ninguno de los dos casos. Los algoritmos implementados se comparan con el valor medido para determinar el grado de desviación asociada. Con esta comparación es posible concluir que la combinación de dos o más técnicas (hibridación) se presenta mejor desempeño y una incertidumbre más baja que si se implementaran técnicas por separado

PALABRAS CLAVE: Generación fotovoltaica, predicción, potencia eléctrica, radiación solar.

ABSTRACT

This article is focused on comparing different prediction techniques for the prediction of photovoltaic power generation with automatic learning techniques. First, is identified the relationship between climatic variables, on which solar generation. With the use of meteorological database (NSBD by NREL), provide the climatic data of the input to the implemented algorithms whose response will be compared in a particular case of photovoltaic power generation, in the city of Popayán in one of the highest radiation months. Two algorithms are implemented, the first one based on a Bayes-Naive classifier without any combination and the second one a Neuronal Network type combined with a Levenberg-Marquardt optimization algorithm. The latter presenting better performance without the implementation of a stage of pre-processing the input data in either case. The implemented algorithms are compared with the measured value to determine the degree of deviation associated. With this comparison it is possible to conclude that the combination of two or more techniques (hybrid) presents better performance and a lower uncertainty than if separate techniques were implemented.

KEYWORDS: Electrical power, forecasting, photovoltaic generation, solar radiation.

1. INTRODUCCIÓN

La generación de electricidad solar está estrechamente ligada a la radiación incidente y variables climáticas en la región donde se quiera implementar el sistema

fotovoltaico (FV). Entre ellas la temperatura ambiente, la velocidad del viento y la nubosidad [1] [2]. Es por esto que las fluctuaciones e intermitencias en la radiación tienen una consecuencia en la producción de energía y el

índice de desempeño de sistemas fotovoltaicos (FV). Las características no controlables de producción de energía solar traen una serie de problemas tales como fluctuaciones de voltaje, calidad de la potencia y problemas de estabilidad [3] [4]. lo que generan pérdidas y efectos adversos en la entrega y despacho final de energía eléctrica.

Una alternativa de aproximación y disminución en la incertidumbre de la estimación de la radiación y por ende de generación solar es utilizar metodologías de predicción que se centren en buscar modelos basados en datos históricos de radiación que determinen la potencia eléctrica entregada de un sistema fotovoltaico en una región en particular; una de estas metodologías es el aprendizaje automático o *Machine Learning* (ML)

La selección de la entrada en el algoritmo, en este caso la radiación incidente debe centrar la atención en el proceso de construcción del modelo final. Como se evidencia en [5] y [6] la precisión del pronóstico varía con el cambio en el tipo y el número de datos de radiación. Estos datos pueden contener varios puntos faltantes, picos y variaciones, por lo tanto se hace necesario implementar una técnica de pre-procesamiento con el objetivo de clasificar y generar patrones de tendencia antes de tener los datos completos de entrada al modelo de pronóstico. Después de eso, los datos históricos de radiación se dividen en dos grupos denominados datos de entrenamiento y prueba. Los datos de entrenamiento del modelo de pronóstico se usan para el aprendizaje del algoritmo y poder predecir valores futuros generando funciones de tendencia. Los datos de prueba se utilizan para analizar el rendimiento del modelo de pronóstico comparando los valores reales y los previstos, en términos de tiempo de convergencia y aproximación al valor especificado. [7]

2. RELACIÓN ENTRE LA PRODUCCIÓN DE POTENCIA FOTOVOLTAICA Y LA RADIACIÓN INCIDENTE.

Para relacionar variables climáticas y la producción de energía solar se ha llegado a modelos de desempeño entre los que cabe destacar: el modelo de desempeño Duffie & Beckman [8], modelo de desempeño King [9] y Modelo de desempeño Masters [10]. En la Ecuación (1) se muestra el modelo de potencia solar P , que es más utilizado en etapas de dimensionamiento y diseño [11].

$$P = V \left[N_p * \left(I_{ph} - I_{rr} * \left(e^{\frac{q*V}{N_s*k*T_c+A}} - 1 \right) \right) \right] \quad (1)$$

Donde V , es el voltaje producido por el panel, N_p y N_s son las celdas en paralelo y serie respectivamente, I_{ph} es la fotocorriente que depende directamente de la radiación incidente, I_{rr} es la corriente de cortocircuito característica del panel, T_c es la temperatura ambiente, A el área del arreglo, q la carga del electrón y k la constante de Boltzman.

La radiación incidente medida sobre una superficie

horizontal ($E_H W/m^2$), varía con la longitud, latitud, y posición del sol bajo parámetros impredecibles de clima. En trabajos previos como [12] [13] [14] [15] [5] se muestra que es importante resaltar el efecto de la radiación solar incidente como precursor de la producción total de energía FV a esto se suma que existe normatividad asociada para establecer los efectos de la radiación en el modelo de energía eléctrica entregada por un arreglo o arreglo de paneles fotovoltaicos. En [16] por ejemplo se establece un procedimiento para determinar un modelo lineal de medida de la radiación el cual depende de los parámetros eléctricos del panel. En [17] presenta una metodología de corrección en la salida de la curva corriente-voltaje debido a las desviaciones ocasionadas por la fluctuación de la radiación medida.

3. ALGORITMOS USADOS EN PREDICCIÓN DE CAPACIDAD DE GENERACIÓN DE ENERGÍA FOTOVOLTAICA

Se muestran técnicas de aprendizaje automático (*Machine Learning*), principalmente usadas en el pronóstico e identificando características propias de cada una; entre ellas: etapas implementadas para la aproximación, precisión con la que se realiza la aproximación de generación de potencia, tiempo de convergencia e incertidumbre asociada a la predicción.

En el caso de las *redes neuronales, o Neural Networks* estudios han demostrado la capacidad de esta técnica para determinar con precisión la serie temporal de datos climáticos [12] [13] [18] [19] [20]. De acuerdo con [15] el error asociado en la predicción oscila entre un 5% y 15%. Según [21] y [22] alrededor del 79% de las técnicas usadas en predicción de potencia se basan en un enfoque de conexiones con red neuronal. Aproximadamente el 20% restante se utilizan técnicas derivadas de redes neuronales tales como lógica difusa, *wavelength*, RBFNN. Según la literatura publicada, los parámetros que influyen en la predicción son muchos, por lo que es difícil adoptar los resultados de otros estudios.

Existe otra técnica denominada *K-nearest Neighbors (k-NN)*, está basada en un algoritmo de reconocimiento de patrones el cual compara el estado original con las muestras entrenadas. Según [23] y [24] cuando son usados en procesos de regresión este modelo predefine las vecindades más próximas al dato que se está buscando; este tipo de modelo es usado cuando se tiene un número de días con radiación y perfil similar, presentado una ventaja respecto a modelos como NN, SVM, puesto que no necesita un entrenamiento previo para encontrar las vecindades entre datos y crean un proceso de optimización propio para determinar el perfil de radiación óptimo.

Las máquinas de soporte vectorial (SVM) usadas en sus orígenes para solucionar problemas de clasificación, hoy en día son aplicados a problemas de regresión y reconocimiento de patrones. El punto fuerte de este algoritmo, según [25] es su capacidad de resolución de



problemas de alta complejidad y alta no-linealidad, trabajan sobre regresión lineal múltiple usando un transformador predictivo de baja complejidad y buen filtrado de datos. De acuerdo a [26], los resultados experimentales muestran que el modelo desarrollado bajo SVM tiene un 27% más de precisión con un horizonte de 24h.

Otra técnica es el *Clasificador Bayes-Naive*. Constituyen una familia de simples clasificadores probabilísticos basados en la aplicación del teorema de Bayes con una fuerte suposición de independencia entre las características. La primera técnica hace un ponderado de pronósticos individuales basados en las apariciones del modelo, generando así n modelo promediado. Un modelo de espacio M compuesto por J modelos $M_j(j = 1, 2, \dots, j)$ es considerado para predecir y , la potencia solar. Si D es el dato de entrenamiento basado en las observaciones de potencia solar y f_j la predicción del modelo j . Como se muestra en la Ecuación 2, la función de densidad de probabilidad de la técnica Bayesiana es un promedio de la distribución posterior $p(y|M_j, D)$ bajo cada modelo considerado, los ponderados de cada probabilidad anterior esta dado por $w_j - P(M_j|D)$ [27]

$$p(y|D) = \sum_{j=1}^J w_j p(y|M_j, D) \quad (2)$$

Solo se requiere una pequeña cantidad de datos de entrenamiento para estimar los parámetros (las medias y las varianzas de las variables) necesarias para la clasificación. En trabajos como [28] y [29] se utilizó esta técnica para pronosticar la radiación teniendo en cuenta una serie temporal con un horizonte de aproximadamente una hora dando mejores tiempos de convergencia y mejores pronósticos que la combinación con regresión lineal y un modelo híbrido de máquinas de soporte vectorial y red neuronal esto en gran parte debido al volumen histórico de datos que se usó para desarrollar la predicción.

Los *modelos híbridos* son diseñados mediante la combinación de dos o más técnicas con atributos superiores y aprovechando las potencialidades individuales. Según [30] y [31] la hibridación de dos o más técnicas muestran mejores resultados que una técnica aislada para el problema de predicción. Una de las mayores motivaciones de un algoritmo híbrido es el explorar las posibilidades de la combinación de diferentes algoritmos para aumentar la precisión. Es como en [32] se implementan dos algoritmos de predicción, el primero basado en un filtro de Kalman y de corto horizonte de predicción (5 minutos) y el segundo un algoritmo de predicción diaria basado Fuzzy Logic.

En el primero el algoritmo utiliza datos instantáneos medidos, entregados por un sistema de adquisición de datos y en la segunda técnica el algoritmo recibe parámetros meteorológicos de días anteriores y en modelos de distribución de tiempo. En [33] el trabajo se centra en estudiar la correlación existente entre las variables meteorológicas y la potencia entregada a la carga eléctrica, para esto se diseña un modelo híbrido basado en el método de clasificación meteorológica y máquinas de soporte vectorial. Los diferentes tipos de día son clasificados en cielo abierto, cielo nublado, día con niebla y día lluvioso. Esta máquina de soporte vectorial fue diseñada para pronosticar carga de 24h en adelante. En [34] se desarrollan tres etapas para obtener una aproximación de un día en la predicción. En la primera etapa con el uso de dos técnicas, se clasifica el histórico de datos de potencia de salida, en la etapa de entrenamiento se utiliza vector de soporte al cual se le suministran los datos de probabilidad de lluvia, temperatura y radiación, todo definido en horas similares. En la etapa de predicción, el método de la interferencia difusa es usado para seleccionar un modelo adecuado de entrenamiento y generar el modelo predictivo basado en probabilidad estocástica. Un compendio de estas técnicas, sus fortalezas y debilidades se muestra en la Tabla 1

4. PREDICCIÓN DE POTENCIA SOLAR EN UNA REGIÓN EN PARTICULAR

En la Figura 1 se muestra el perfil de irradiancia solar, (W/m^2), modelada sobre una superficie horizontal, para la ciudad de Popayán, (Latitud: $2^{\circ}26.2938' N$; Longitud: $76^{\circ}36.7896' O$), los datos corresponden al año 2015, tomados cada 30 minutos utilizando la base de datos de [35]; cabe resaltar que el recurso solar está disponible desde aproximadamente las 5am hasta las 7pm, el resto de los datos horarios de potencia solar no es relevante puesto no produce energía eléctrica.




Figura 1. Potencia solar (Popayán, 2015) por cada 30 minutos.

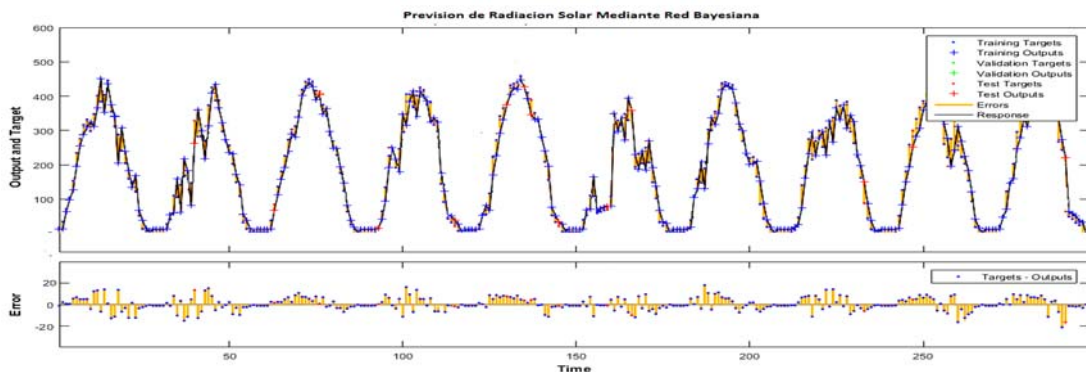
Tabla 1. Lista de trabajos representativos relacionados con la predicción de potencia fotovoltaica utilizando aprendizaje automático .

<i>Autores</i>	<i>Título</i>	<i>Año</i>	<i>Revista</i>	<i>Resultados</i>
Athanasios Zagouras, Hugo T.C. Pedro, Carlos F.M. Coimbra [36]	On the role of lagged exogenous variables and spatio-temporal correlations in improving the accuracy of solar forecasting methods	2015	Renewable Energy N°78	Se muestra que el uso de algoritmos de predicción de regresión lineal y un algoritmo genético para optimizar la selección de múltiples variables exógenas da como resultado mejoras significativas (8.458-40.419%) que los modelos de referencia..
William R. Burrows [37]	CART Regression Models for Predicting UV Radiation at the Ground in the Presence of Cloud and Other Environmental Factors	1997	Journal Of Applied Meteorology	Compara dos algoritmos de predicción, el primero basado en una técnica de regresión lineal de paso y el segundo basado en regresión con árboles de decisión. Encontrando que el desempeño del segundo es mayor que el primero en términos de cálculo de la incertidumbre (entre 5-1'0%)
Christophe Paoli, Cyril Voyant, Marc Muselli, Marie-Laure Nivet, [38]	Forecasting of preprocessed daily solar radiation time series using neural networks	2010	Solar Energy	La implementación de redes neuronales tiene mejor desempeño esto depende del enfoque de pre procesamiento de datos el cual puede reducir la incertidumbre de predicción de aproximadamente el 6% en comparación con regresión automática, inferencia Bayesiana o cadena de Markov.
P. Krömer, P. Musilek, E. Pelikán, P. Krč, P. Juruš y K. Eben [14]	Support Vector Regression of multiple predictive models of downward short-wave radiation	2014	International Joint Conference on Neural Networks	Se encuentra que los pronósticos basados en SVR comparado con predicción numérica en múltiples ubicaciones muestran una mejora significativa de la precisión
S. Salcedo-Sanz, C. Casanova-Mateo, A. Pastor-Sánchez, M. Sánchez-Girón [39]	Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization – Extreme Learning Machine approach	2014	Solar Energy	Enfoque Coral-ELM es capaz de obtener una predicción exacta de la radiación global diaria, mejor que el ELM clásico, y el algoritmo de soporte vectorial.

En la Figura 1, se muestra que entre los meses de Enero-Mayo y Agosto-Diciembre se presentan los mayores valores de potencia solar, mientras que entre mitad de año Junio-Julio aproximadamente decrece, lo que genera que la producción de electricidad FV en una instalación solar también lo haga. Las observaciones para implementar las técnicas de previsión están tomadas en 10 días para el mes de Junio, cada media hora entre las 5am y 7pm. Las técnicas seleccionadas a implementar son un algoritmo de Red Bayesiana y de red neuronal

combinado con un algoritmo de optimización Levenberg-Marquardt

La Figura 2, muestra la comparación de la radiación medida con los resultados de la predicción usando Red Bayesiana. En esta técnica el 60% de los datos correspondieron a etapa de entrenamiento, el 20% a etapa de validación y el 20% restante a la etapa de prueba. El entrenamiento de los datos se realiza en forma cerrada y por tiempo lineal, en lugar de una costosa aproximación iterativa como en otros tipos de algoritmos.

**Figura 2.** Comparación entre la potencia solar medida y el modelo predictivo Red Bayesiana.(Popayán, Colombia, 2015)

En la Figura 2, también se muestra el error cuadrático medio (MSE) asociado a la validación del modelo frente a los resultados medidos, en total la incertidumbre asociada a esta técnica está cerca del 18%, teniendo en cuenta la relación entre dato objetivo/salida del modelo. En la Figura 3 muestra los resultados del algoritmo de Red Neuronal y su comparación con las medidas realizadas, cabe resaltar que para las etapas de entrenamiento, validación y prueba se utilizan la misma proporción de datos que para el apartado anterior. Para esta técnica se presenta una incertidumbre asociada a la medida de entre un 10 a 15%, un 5% menor que usando la técnica de Red Bayesiana, esto debido al optimizador

implementado, que hace que la búsqueda de valores predictivos sea más eficiente al evaluar valores, compararlos, si es el caso descartarlos o aceptarlos según la etapa de validación; la cual depende directamente de los datos medidos.

La respuesta de los modelos frente a la generación de potencia solar depende fuertemente de las condiciones específicas de la hora del día, es así como se presenta mejor desempeño de los modelos en días soleados, con una incertidumbre asociada de aproximadamente el 6%; mientras que para días nublados se incrementa hasta niveles del 16% aproximadamente.




Figura 3. Comparación entre la potencia solar medida y el modelo predictivo Red Neuronal.(Popayán, Colombia, 2015)

En las Figuras 4 y 5 se muestran las rectas de entrenamiento y relación entre los valores de salida aproximados para cada uno de los algoritmos implementados y los valores medidos. Según las sub figuras 4a y 4c se presentan mejores resultados en los objetivos de predicción 24 y 25, debido en parte al alto volumen de datos que fue considerado para la etapa de entrenamiento, mientras que la Figura 4c, presenta una dispersión mayor en la recta de regresión; hay que tener en cuenta que existen sesgos sistemáticos y desviaciones dependiendo de las condiciones de potencia solar y el rango de las desviaciones están relacionadas con las previsiones.

Para el segundo algoritmo implementado las Figuras 5a y 5c muestra que existe una relación de convergencia hasta aproximadamente en el dato objetivo 70; lo que indica la conveniencia de este tipo de modelos híbridos en estudios de predicción solar.




Figura 4 Desviaciones en rectas de entrenamiento usando red Bayesiana.




Figura 5. Desviaciones en rectas de entrenamiento usando NN+LVQ

En la Figura 6 se muestra los resultados de la comparación entre los algoritmos seleccionados. De acuerdo con la gráfica, hay mayor precisión en el pronóstico cuando se implementa una solución combinada (NN+LVM) que una solución de ML sin combinaciones. Esto es debido en gran parte a la etapa de optimización implementada, lo que permite reducir costos computacionales y así disminuir la incertidumbre asociada a encontrar el dato de radiación requerido.




Figura 6. Resultados de comparación entre potencia de radiación medida y algoritmos implementados

5. CONCLUSIÓN

En este trabajo se pretende comparar a través de un estudio de caso, diferentes algoritmos utilizados en la predicción de potencia solar. Para ello, la primera etapa es conocer el modelo matemático de potencia derivado del modelo eléctrico que brinda la relación de producción de electricidad FV dependiente de variables climáticas y propias del material. Luego, mediante una revisión bibliográfica, se muestra la existencia de diferentes técnicas de predicción de potencia solar basado en aprendizaje automático identificando sus características propias y fortalezas/debilidades. Posteriormente se implementó en un estudio de caso la predicción de potencia para una región en particular, usando una técnica de red Bayesiana y una técnica NN combinado con algoritmo de optimización Levenberg-Marquardt. Para este estudio de caso no se tiene implementado un clasificador para diferentes tipos de día, como nuboso, claro y lluvioso, lo que contribuiría a la minimización de incertidumbres asociadas y mejoraría el rendimiento de los algoritmos- Además de eso cada dato contribuye al desempeño y capacidad de aprendizaje del modelo de predicción; estos datos están ligados a la naturaleza de eventos meteorológicos, tasas de rampa, de baja, escalón etc. La precisión en la predicción de potencia, teniendo en cuenta la incertidumbre, se puede mejorar mediante el pre y post procesamiento de los datos usados para entrenar el modelo.

6. REFERENCIAS.

- [1] A. Bouraiou, M. Hamouda, A. Chaker, M. Mostefaoui, S. Lachtar, M. Sadok, N. Boutasseta, M. Othmani y A. Issam, «Analysis and evaluation of the impact of climatic conditions on the photovoltaic modules performance in the desert environment,» *Energy Conversion and Management*, vol. 106, pp. 1345-1355, 2015.
- [2] M. E. Flowers, M. K. Smith, A. W. Parsekian, D. S. Boyuk, J. K. McGrath y L. Yates, «Climate impacts on the cost of solar energy,» *Energy Policy*, vol. 94, pp. 264-273, 2016.
- [3] E. Ghiani, F. Pilo y S. Cossu, «Evaluation of photovoltaic installations performances in Sardinia,» *Energy Conversion and Management*, vol. 76, pp. 1134-1142, 2013.
- [4] M. Mitchell, M. Campbell, K. Klement y M. Sedighy, «Power variability analysis of megawatt-scale solar photovoltaic installations,» de *IEEE Electrical Power and Energy Conference (EPEC)*, Ottawa, 2016.
- [5] R. Golbaba, K. Sudirman y M. Ashenayi, «Comparison of Methods Used for Forecasting Solar Radiation,» de *IEEE Green Technologies Conference*, Tulsa, OK, 2012.
- [6] D. v. d. Meer, J. Widén y J. Munkhammar, «Review on probabilistic forecasting of photovoltaic power production and electricity consumption,» *Renewable and Sustainable Energy Reviews*, 2017.
- [7] C. Bishop, *Pattern Recognition and Machine Learning*, New York: Springer-Verlag, 2006.
- [8] D. J y B. W.A, *Solar Engineering of Thermal Processes*, Madison, Wisconsin: Jhon Wiley & Sons, 1980.
- [9] D. King, W. Boyson y J. Kratochvill, «Photovoltaic Array Performance Model SANDIA REPORT SAND2004-3535,» Sandia, Sandia California, 2004.
- [10] M. G, *Renewable and Efficient Electric Power Systems*, John Wiley & Sons, 2004.
- [11] V. M. Labouret, *Solar Photovoltaic Energy*, The Institution of Engineering and Technology of United Kingdom., 2009.
- [12] C. Dong, B. Sigrin y G. Brinkman, «Forecasting residential solar photovoltaic deployment in California,» *Technological Forecasting and Social Change*, vol. 117, pp. 251-265, 2017.
- [13] B. Amrouche y X. L. Pivert, «Artificial neural network based daily local forecasting for global solar radiation,» *Applied Energy*, vol. 130, pp. 333-341, 2014.

- [14] P. Krömer, P. Musílek, E. Pelikán, P. Krč, P. Juruš y K. Eben, «Support Vector Regression of multiple predictive models of downward short-wave radiation,» de *International Joint Conference on Neural Networks*, Beijing, 2014.
- [15] C. Voyant, G. Notton, S. Kalogirou, M.-L. Nivet, C. Paoli, F. Motte y A. Fouilloy, «Machine learning methods for solar radiation forecasting: A review,» *Renewable Energy*, vol. 105, pp. 569-582, 2017.
- [16] International Electrotechnical Commission, *IEC 60904-10:2009 Photovoltaic devices - Part 10: Methods of linearity measurement*, 2010.
- [17] International Electrotechnical Commission, *IEC 60891:2009 Photovoltaic devices - Procedures for temperature and irradiance corrections to measured I-V characteristics*, 2009.
- [18] E. G. Kardakos, M. C. Alexiadis, S. I. Vagropoulos, C. K. Simoglou, P. N. Biskas y A. G. Bakirtzis, «Application of time series and artificial neural network models in short-term forecasting of PV power generation,» de *Power Engineering Conference (UPEC)*, Dublin, 2013.
- [19] S. LevaL, A. Dolara, F. Grimaccia, M. Mussetta y E. Ogliari, «Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power,» *Mathematics and Computers in Simulation*, vol. 131, pp. 88-100, 2017.
- [20] K. Gairaa, F. Chellali, S. Benkacali, Y. Messlem y K. Abdallah, «Daily global solar radiation forecasting over a desert area using NAR neural networks comparison with conventional methods,» de *International Conference on Renewable Energy Research and Applications (ICRERA)*, Palermo, 2015.
- [21] A. Mellit, S. Kalogirou, L. Hontoria y S. Shaari, «Artificial intelligence techniques for sizing photovoltaic systems: A review,» *Renewable and Sustainable Energy Reviews*, vol. 13, nº 2, pp. 406-419, 2009.
- [22] M. Q. Raza, M. Nadarajah y C. Ekanayake, «On recent advances in PV output power forecast,» *On recent advances in PV output power forecast, Solar Energy*, vol. 136, pp. 125-144, 2016.
- [23] Y. Zhang, M. Beaudin, R. Taheri, H. Zareipour y D. Wood, «Day-Ahead Power Output Forecasting for Small-Scale Solar Photovoltaic Electricity Generators,» *IEEE Transactions on Smart Grid*, vol. 6, nº 5, pp. 2253-2262, 2015.
- [24] H. T. Pedro y C. F. Coimbra, «Assessment of forecasting techniques for solar power production with no exogenous inputs,» *Solar Energy*, vol. 86, nº 7, pp. 2017-2028, 2012.
- [25] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. Martinez-de-Pison y F. Antonanzas-Torres, «Review of photovoltaic power forecasting,» *Solar Energy*, vol. 136, pp. 78-111, 2016.
- [26] «Machine Learning Techniques for Supporting Renewable Energy Generation and Integration: A Survey,» de *Lecture Notes in Computer Science book series*, Springer, 2014, pp. 81-96.
- [27] J. A. Hoeting, D. Madigan, A. E. Raftery y C. T. Volinsky, «Bayesian Model Averaging: A Tutorial,» *Statistical Science*, vol. 14, nº 4, pp. 382-398, 1999.
- [28] A. Bracale, G. Carpinelli y P. D. Falco, «Bayesian-based approach for the short-term forecasting of electrical loads in smart grids. Part II: numerical applications,» de *2016 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, Anacapri, 2016.
- [29] P. Chakraborty, M. Marwah, M. Arlitt y N. Ramakrishnan, «Fine-grained Photovoltaic Output Prediction using a Bayesian Ensemble,» 2012. [En línea]. Available: <http://people.cs.vt.edu/naren/papers/chakraborty-aaai12.pdf>. [Último acceso: 20 08 2017].
- [30] M. Q. Raza y Z. Baharudin, «A review on short term load forecasting using hybrid neural network techniques,» de *IEEE International Conference on Power and Energy (PECon)*, Kota Kinabalu, 2012.
- [31] M. Q. Raza y A. Khosravi, «A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings,» *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 1352-1372, 2015.
- [32] M. Chaabene y M. B. Ammar, «Neuro-fuzzy dynamic model with Kalman filter to forecast irradiance and temperature for solar energy systems,» *Renewable Energy*, vol. 33, nº 7, pp. 1435-1443, 2008.
- [33] L. Hernández, C. Baladrón, A. JM., L. Calavia, B. Carro, A. Sánchez-Esguevillas, D. Cook, D. Chinarro y J. Gómez, «A Study of the Relationship between Weather Variables and Electric Power Demand inside a Smart Grid/Smart World Framework,» *Sensors*, vol. 12, nº 9, pp. 11571-11591, 2012.
- [34] H. T. Yang, C. M. Huang, Y. C. Huang y Y. S. Pai, «A Weather-Based Hybrid Method for 1-Day Ahead Hourly Forecasting of PV Power Output,» *IEEE Transactions on Sustainable Energy*, vol. 5, nº 3, pp. 917-926, 2014.

- [35] National Renewable Energy Laboratory NREL, «National Solar Radiation Database NSRDB,» [En línea]. Available: <https://nsrdb.nrel.gov/contact>. [Último acceso: 30 06 2017].
- [36] A. Zagouras, H. T. Pedro y C. F. Coimbra, «On the role of lagged exogenous variables and spatio-temporal correlations in improving the accuracy of solar forecasting methods,» *Renewable Energy*, vol. 78, pp. 203-218, 2015.
- [37] W. R. BURROWS, «CART Regression Models for Predicting UV Radiation at the Ground in the Presence of Cloud and Other Environmental Factors,» *JOURNAL OF APPLIED METEOROLOGY*, vol. 36, pp. 531-544, 1997.
- [38] C. Paoli, C. Voyant, M. Muselli y M.-L. Nivet, «Forecasting of preprocessed daily solar radiation time series using neural networks,» *Solar Energy*, vol. 84, n° 12, pp. 2146-2160, 2010.
- [39] S. Salcedo-Sanz, C. Casanova-Mateo, A. Pastor-Sánchez y M. Sánchez-Girón, «Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization – Extreme Learning Machine approach,» *Solar Energy*, vol. 105, pp. 91-98, 2014.
- [40] Fundacion Telefonica, *Introducción al Machine Learning*.

