

PREDICCIÓN DE POTENCIA FOTOVOLTAICA MEDIANTE REDES NEURONALES WAVELET

José Daniel Ortiz López

Instituto Tecnológico Superior Progreso

danielortizlopez9@gmail.com

Luis J. Ricalde Castellanos

Universidad Autónoma de Yucatán, Facultad de Ingeniería

lricalde@correo.uady.mx

Braulio J. Cruz Jiménez

Universidad Autónoma de Yucatán, Facultad de Ingeniería

Ricardo J. Peón Escalante

Universidad Autónoma de Yucatán, Facultad de Ingeniería

lricalde@correo.uady.mx

Resumen

En el presente trabajo se realiza la predicción de potencia de un sistema solar fotovoltaico implementando dos diferentes estructuras de redes neuronales, perceptrón multicapa y una red neuronal wavelet. El algoritmo de aprendizaje utiliza información proveniente de la irradiación, temperatura, humedad relativa y velocidad del viento. Los datos de entrenamiento se obtienen de una estación meteorológica ubicada cerca de un sistema fotovoltaico de 7 kW. El perceptrón multicapa tuvo como entradas las cuatro variables mencionadas anteriormente y como salida la potencia del sistema, la red Wavelet únicamente tuvo como entrada la irradiación y como salida la potencia generada por el sistema fotovoltaico. Se obtuvieron mejores resultados en la predicción de la red wavelet, siendo esta una de las principales aportaciones de este trabajo.

Palabras Claves: Fotovoltaico, perceptrón multicapa, red neuronal, wavelet.

Abstract

This work presents the prediction of power of a solar photovoltaic system implementing two different neural networks, multilayer perceptron and wavelet neural network. The learning algorithm uses information from irradiance, temperature, relative humidity and wind speed. The training data are obtained from a weather station located near a 7 kW photovoltaic system. The multilayer perceptron had as inputs four variables previously mentioned and as output the power. The wavelet network only had as input the irradiation and as output, the power generated by the photovoltaic system. Better results were obtained in the prediction of the wavelet network, being this one of the main contributions of this work.

Keywords: *Multilayer perceptron, neuronal network, photovoltaic, wavelet.*

1. Introducción

Es evidente un incremento de la demanda energética de la población, propiciando una amenaza de una crisis energética mundial, lo que ocasiona efectos negativos ambientales hacia nuestro hábitat [Rubio, 2016]. El uso eficiente de la energía es una problemática que ha causado gran interés en el mundo debido a que la materia prima (combustibles fósiles) presenta una baja importante en las reservas internacionales, ocasionando serios problemas económicos, políticos y sociales [IMF, 2011]

La importancia a las energías renovables ha ido en aumento, esto se puede ver desde la integración de ellas en las redes públicas de energía [Almonacid, 2015], hasta la aplicación de tecnologías como las redes neuronales en la predicción de la producción energética, así como la aplicación de diferentes técnicas para obtener una optimización en el proceso de predicción [Fernández, 2014], [Lopez, 2016]. El desarrollo de modelos de predicción energética es una tarea importante, permitiendo optimizar y rentabilizar al máximo un sistema de producción energético.

Las redes neuronales se han aplicado en muchos ámbitos probando ser eficaces en el reconocimiento de patrones, procesamiento de imágenes, detección de

fallas, control y predicción. Las redes neuronales han demostrado tener diferentes campos aplicativos como [Martin, 2006] donde se propone una red neuronal artificial como herramienta para predecir si la calidad de una unión soldada por resistencia por puntos alcanza o no un cierto nivel a partir de tres parámetros operativos (tiempo de soldadura, intensidad de corriente y tipo de electrodo). La implementación de inteligencia artificial en el control, monitoreo y procesamiento de información relacionada en la energía renovable es día a día mas empleada, en [Forero, 2013] se emplean redes neuronales para el control de una planta prototipo de gasificación de biomasa. En [Yadav, 2017] se identifican los factores más importantes en la predicción de la potencia de un sistema solar fotovoltaico. En [Holtschneider, 2013] se puede ver la aplicación de las redes neuronales en la variación y ajustes de precios dinámicos de la energía eléctrica con respecto a la demanda de los usuarios lo cual se puede apoyar en modelos de predicción de energía eléctrica basados en redes neuronales.

En este trabajo, las mediciones de generación fotovoltaica se tomaron a partir de una instalación fotovoltaica de 7 kW, mostrada en la figura 1, este sistema se encuentra interconectado a la red pública de distribución eléctrica mediante inversores. Los módulos fotovoltaicos empleados en esta micro red son de la marca Solartec, modelo S60PC de 250 watts. Los valores de generación energética de esta instalación fueron utilizados para la predicción de generación de potencia.



Figura 1 Sistema de generación fotovoltaico.

En este trabajo, se emplea un perceptrón multicapa, y una red neuronal wavelet para la predicción de potencia, generada por el sistema fotovoltaico conectado a la red pública; aportando también el diseño de un algoritmo basado en el filtro extendido de Kalman para aproximar los valores reales de la producción de dicho sistema.

2. Métodos

Redes Neuronales Artificiales

Una red neuronal artificial es un modelo simple de una red biológica cuya finalidad es almacenar conocimiento retenido de manera experimental y generalizarlo para estímulos similares. La forma en la que una red neuronal aprende se denomina algoritmo de entrenamiento, el cual modifica los pesos sinápticos de la red para poder atender al objetivo deseado [Haykin, 2005]. La figura 2 representa un modelo básico de una neurona la cual se pueden apreciar los elementos básicos que la componen, entradas, pesos sinápticos, sumador, umbral y la función de activación.




Figura 2 Modelo de una neurona artificial.

Filtro de Kalman y Filtro Extendido de Kalman

El filtro de kalman proporciona una solución recursiva al problema del filtrado lineal óptimo, mediante la formulación del espacio de sistemas dinámicos lineales. El filtro de Kalman se define a partir de las ecuaciones 1 a 5.

$$\hat{w}^-(k) = F_{k,k-1} \hat{w}^-(k-1) \quad (1)$$

$$P^-(k) = F_{k,k-1} P(k-1) F_{k,k-1}^T + Q(k-1) \quad (2)$$

$$K(k) = P^-(k) H^T(k) [H(k) P^-(k) H^T(k) + R(k)]^{-1} \quad (3)$$

$$\hat{w}(k) = \hat{w}^-(k) + K(k) (y(k) - H(k) \hat{w}^-(k)) \quad (4)$$

$$P(k) = (I - K(k) H(k)) P^-(k) \quad (5)$$

Donde la ecuación 1 representa la propagación del estado estimado; la 2 la propagación de la covarianza del error; la 3 es la matriz de ganancia de Kalman; la 4 es la actualización del estado estimado y finalmente la ecuación 5 es la actualización de la covarianza del error [Haykin, 2001].

El filtro extendido de kalman es un proceso de linealización aplicable a un modelo lineal de un sistema dinámico [Haykin, 1999]. El filtro extendido de Kalman considera un sistema dinámico no lineal en espacio de estado que se describe por ecuaciones 6 y 7.

$$w(k+1) = f(k, w(k)) + u(k) \quad (6)$$

$$y(k) = h(k, w(k)) + v(k) \quad (7)$$

Donde $u(k)$ y $v(k)$ son ruidos independientes blancos, gaussianos con media cero y matrices de covarianza $Q(k)$ y $R(k)$, $f(k, w(k))$ es la función matricial no lineal de transición la cual puede variar con respecto al tiempo; $h(k, w(k))$ denota la función matricial de medición no lineal que puede variar con respecto al tiempo.

Aproximando las ecuaciones 6 y 7 a un estado no lineal, se obtienen ecuaciones 8 y 9.

$$w(k+1) \approx F_{k+1,k} w(k) + u(k) + d(k) \quad (8)$$

$$\bar{y}(k) \approx H(k) w(k) + v(k) \quad (9)$$

Red Neuronal Wavelet

La transformada de Wavelet tiene como idea básica mapear funciones pertenecientes al espacio L^2 al espacio de fase-frecuencia, esto para permitir que

los coeficientes reflejen las propiedades de tiempo-frecuencia presentes en la función de origen. La función llamada Wavelet madre es la que se tiene que escalar y trasladar, para obtener la proyección de una función original a una familia de funciones [Zhang, 1992].

Las redes neuronales Wavelet radiales tienen la complejidad computacional en el cálculo de $\psi(x)$ ya que está compuesto del cálculo de la norma de $x \in \mathbb{R}^n$ y la evaluación no lineal univariable de ϕ . La función wavelet para una red neuronal se define mediante ecuación 10.

$$\psi(x) = \phi(|x|) \tag{10}$$

A partir de ecuaciones 11 a la 13.

$$C_\psi \triangleq \int \frac{|\tilde{\psi}(w)|^2}{|w|} dw < \infty \tag{11}$$

$$g(x) = \sum_{i=1}^N w_i \psi(d_{wi}(x - t_i)) \tag{12}$$

$$g(x) = \sum_{i=1}^N w_i \psi(d_{wi}(x - t_i)) + b \tag{13}$$

En ecuación 13 vemos la aproximación de cualquier función del espacio L^2 a partir de ecuación 12, utilizando b que es el umbral añadido a la neurona de la capa de salida [Zhang, 1992].

Algoritmos de Aprendizaje

La red neuronal wavelet es entrenada mediante el algoritmo del filtro de Kalman. En la figura 4 se muestra la arquitectura de la red propuesta.




Figura 4 Estructura de una red neuronal wavelet.

La capa oculta 1 está constituida por L neuronas, la función de activación utilizada en esta sección es la función Wavelet radial Mexican Hat, la cual se encuentra definida por ecuaciones 14 y 15.

$$\psi(x_j) = (x_j^T x_j - n_\alpha) e^{-\frac{x_j^T x_j}{2}}, \quad j = 1, \dots, L \quad (14)$$

$$x_j = d_{wji}(\varrho_i - t_{ji}), \quad i = 1, \dots, n_\alpha; \quad j = 1, \dots, L$$

$$d_{wji} = 2^r$$

$$t_{ji} = \frac{2t_{ri} - \text{sing}(t_{ri})}{d_{wji}} \quad (15)$$

$$t_{ri} = |2^{r-1} \varrho_i| \text{sing}(\varrho_i)$$

$$\text{sing}(\cdot) \begin{cases} 1 & \text{si } (\cdot) > 0 \\ 0 & \text{si } (\cdot) = 0 \\ -1 & \text{si } (\cdot) < 0 \end{cases}$$

Los parámetros de escalamiento y traslación de la Wavelet madre están representados por d_{wji} y t_{ji} respectivamente en ecuación 15; r son los niveles de resolución deseado en la función no lineal. Los pesos sinápticos son actualizados mediante un algoritmo de aprendizaje, esto ocasiona que los parámetros de escalamiento y traslación sean constantes en aprendizaje e independientes de k . La capa oculta 2 contiene la función de activación sigmoide logística con A unidades. Debido a que solo existe una neurona con función de activación lineal en la capa de salida, el conjunto de ecuaciones 16 se aplican para la capa oculta.

$$y_j = \psi(x_j)$$

$$v_i(k) = \sum_{j=0}^L w_{ij}(k) y_j$$

$$y_i(k) = \varphi(v_i(k)) = \frac{1}{1 + e^{(-av_i(k))}} \quad (16)$$

$$v(k) = \sum_{i=0}^A w_i(k) y_i(k)$$

$$\hat{y}(k) = \varphi(v(k)) = v(k)$$

Entrenamiento con el Filtro Extendido de Kalman

La red neuronal Wavelet puede ser representada y aproximada por ecuaciones 17 y 18.

$$w(k+1) = w(k) + K(k) [y(k) - \hat{y}(k)] \quad (17)$$

$$\hat{y}(k) = h(w(k), \varrho(k)) \quad (18)$$

La actualización de los pesos sinápticos con cada iteración, de la red neuronal Wavelet está comprendida por el conjunto de ecuaciones 19.

$$K(k) = P(k)H^T(k)[R + H(k)P(k)H^T(k)]^{-1} \quad (19)$$

$$w(k+1) = w(k) + K(k)[y(k) - \hat{y}(k)]$$

$$P(k+1) = P(k) - K(k)H(k)P(k) + Q$$

Entrenamiento de Filtro de Kalman para Red Neuronal Wavelet

La obtención de la matriz $H(k)$, se denota en dos partes $H_1(k)$ denota a la salida de la red neuronal con respecto a los pesos de la capa oculta 2 y $H_2(k)$ la derivada de la salida de la red neuronal con respecto a los pesos de la salida de la misma capa. Entonces los valores de $H_1(k)$ y $H_2(k)$ se calculan mediante ecuaciones 20 y 21, recordando que solamente se cuenta con una salida.

$$H_1(k) = \frac{\partial \hat{y}(k)}{\partial w_{ij}(k)} = \frac{\partial \hat{y}(k)}{\partial v(k)} \frac{\partial v(k)}{\partial y_1(k)} \frac{\partial y_1(k)}{\partial w_{ij}(k)} \quad (20)$$

$$H_2(k) = \frac{\partial \hat{y}(k)}{\partial w_1(k)} = \frac{\partial \hat{y}(k)}{\partial v(k)} \frac{\partial v(k)}{\partial w_1(k)} \quad (21)$$

Una vez obtenidos los resultados de las derivadas parciales, se procede a sustituir en ecuaciones 20 y 21, obteniendo así la matriz $H(k)$, ecuaciones 22 y 23.

$$H_1(k) = \frac{w_1(k) \cdot \alpha s^{(-\alpha v_1(k))} \cdot y_1}{(1 + s^{(-\alpha v_1(k))})^2} \quad (22)$$

$$H_2(k) = y_1(k) \quad (23)$$

Algoritmo de Retropropagación Levenberg-Marquardt

El algoritmo Levenberg-Marquardt, se puede derivar en 4 partes, el algoritmo de descenso, método de Newton, el algoritmo de Gauss-Newton y el algoritmo Levenber-Marquardt [Hao, 1992]. En la tabla 2 se muestra el resumen de los 3 primeros métodos, en donde se expresa solamente la función de actualización de los pesos sinápticos.

Tabla 2 Derivación del algoritmo Levenberg-Marquardt.

Método	Regla de actualización de los pesos
Algoritmo de descenso	$w_{k+1} = w_k - \alpha g_k$
Método de Newton	$w_{k+1} = w_k - H_k^{-1} g_k$
Algoritmo de Gauss-Newton	$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k e_k$

Partiendo de la tabla anterior en el algoritmo Levenberg-Marquardt, se debe asegurar que la matriz $J^T J$ es invertible, es por eso que se introduce la siguiente aproximación dada por ecuación 24.

$$H = J^T J + \mu I \quad (24)$$

Donde μ el coeficiente de combinación, es la matriz identidad.

Es notorio ver que de la ecuación 40 los elementos de la matriz general serán mayores que cero, comprobando que la matriz es invertible. Combinando la ecuación de actualización de pesos del algoritmo de Gauss-Newton con ecuación 24, se obtiene la actualización de los pesos del algoritmo Levenberg-Marquardt [Hao, 2011], ecuación 25.

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (25)$$

Análisis de Variables en Sistemas Fotovoltaicos

Con el objetivo de conocer cuales datos deben de alimentar el modelo, se realizó un análisis de las series de tiempo obtenidas de las mediciones de la estación meteorológica para estimar la correlación que existe entre la potencia producida y las variables independientes de radiación, velocidad de viento, dirección del viento, humedad relativa y temperatura ambiente, de donde se obtienen los resultados de las principales variables mostrados en la tabla 3.

Tabla 3 Coeficientes de correlación de variables a emplear.

Variable	Coeficiente de Correlación
Irradiación	0.9311
Temperatura	0.6926
Velocidad del viento	0.2852
Humedad	-0.6516

3. Resultados

Se comparan dos estructuras de redes neuronales el perceptrón multicapa y una red neuronal Wavelet utilizando los algoritmos de aprendizaje Levenberg-Marquardt y el filtro de Kalman respectivamente. Las entradas a la red neuronal perceptrón fueron irradiación (W/m^2), humedad relativa (%), temperatura ($^{\circ}C$) y velocidad del viento (m/s), esto para predecir la potencia producida por el sistema. Para la red neuronal Wavelet se utilizó la irradiación (W/m^2), para predecir la potencia producida por el sistema.

Predicción Mediante Perceptrón Multicapa

La predicción por medio de esta red neuronal se realizó utilizando 4 variables de fueron irradiación (W/m^2), humedad relativa (%), temperatura ($^{\circ}C$) y velocidad del viento (m/s), la salida de la red neuronal fue la potencia producida durante 7 días por el sistema fotovoltaico como se ve en la figura 5. Para esta simulación se tuvieron 2016 datos por cada variable, se diseñó un perceptrón multicapa con 200 neuronas en su capa oculta y 1 neurona en su capa de salida, utilizando la función de activación tangente sigmoideal.




Figura 5 Generación de potencia de 7 días, del sistema fotovoltaico.

En la predicción del perceptrón multicapa, los pesos iniciales se seleccionaron aleatoriamente, ya que estos se adaptarán al error de aproximación de su condición inicial. Se utilizó el algoritmo Levenberg-Marquardt para el entrenamiento. La figura 6 muestra la predicción de la potencia generada durante 1500 épocas.




Figura 6 Predicción de la potencia con 1500 épocas.

Predicción con Red Wavelet

Para esta red se utilizaron 200 épocas, con 6 neuronas en la primera capa oculta, 14 neuronas en la segunda capa oculta, las matrices covarianza $P_0=100$, Q_0 y $R_0=250$, se utilizó como entrada a la red la variable de irradiación (W/m^2). La figura 7 muestra la predicción de la red Wavelet entrenada por el filtro extendido de Kalman, donde se puede apreciar un excelente desempeño a pesar de ser entrenada con menos información que en el caso del perceptrón.




Figura 7 Predicción de potencia red Wavelet.

4. Discusión

En la tabla 4 se muestran los resultados de las pruebas de la red neuronal perceptrón multicapa, considerando diferentes entradas para evaluar el desempeño contra la carga computacional y comparar con el error obtenido por la red wavelet solamente con la entrada de irradiación que tuvo un error cuadrático medio de 2.62×10^{-3} . Es evidente que a mayor cantidad de información el desempeño mejora con el costo de un mayor tiempo de cómputo.

Tabla 4 Errores en la predicción del perceptrón multicapa y red neuronal wavelet.

Entradas	Error cuadrático
RNA1(R)	4.09×10^{-3}
RNA2(R,T)	3.82×10^{-3}
RNA3(R,T,H)	3.83×10^{-3}
RNA4(R,T,H,V)	3.21×10^{-3}
Red neuronal wavelet(R)	2.62×10^{-3}

5. Conclusiones

En este trabajo se diseñaron e implementaron dos algoritmos de redes neuronales, para poder predecir la producción energética de un arreglo fotovoltaico. La red neuronal wavelet presentó mayor velocidad de convergencia y se pudo notar que el perceptrón tiene ciertos problemas con cambios bruscos en la señal. La red Wavelet se entrenó solo con la variable de irradiación siendo considerable el resultado obtenido ya que el perceptrón requiere 4 variables para realizar una predicción aceptable. La principal aportación de este trabajo es la propuesta de una estructura neuronal con funciones wavelets capaz de lograr una predicción de potencia de un sistema solar fotovoltaico, utilizando únicamente la irradiación incidente sobre el lugar como dato de entrenamiento.

6. Bibliografía y Referencias

- [1] Almonacid, F., Fernandez, E., Mallick T., & Perez, P., High concentrator photovoltaic module simulation by neural networks using spectrally corrected direct normal irradiance and cell temperature. *Energy*. 84, pp. 336-343, 2015.
- [2] Holtschneider T. & Erlich I., Optimization of Electricity Pricing Considering Neural Network based Model of Consumers Demand Response. *IEEE (CIASG)*. 154-160, 2013.
- [3] Haykin S., *Neural networks and learning machines*. Pearson. Canada, 1999.
- [4] Haykin S., *Kalman filtering and neural networks*. John Wiley & sons, USA, 2001.
- [5] Fernández E., Almonacid, F., Sarmah, N., Rodrigo, P., Mallick, T., & Pérez, P., A model based on artificial neural network for the prediction of the

- maximum power of a low concentration photovoltaic module for building integration. *Solar Energy*.100, pp. 148-158, 2014.
- [6] Hao, Y. & Wilamowski, B. (2011). *Levenberg-Marquardt Training Industrial Electronics Handbook Intelligent Systems*. (2a ed.). CRC Press, 2011.
- [7] Haykin S., *Neural networks a comprehensive foundation*. (2a ed.), 2005.
- [8] IMF, *Tensions from the two-speed recovery unemployment, commodities, and capital flows*. Washington D.C. USA, 2011.
- [9] Lopez J., Ramos, J., Zulueta, E., Fernandez, U., & Oterino, F. *Systematic modeling of photovoltaic modules based on artificial neural networks*". *Hydrogen energy*. 41, pp. 1267-12687, 2016.
- [10] Martin O., Lopez M. & Martin F., *Redes neuronales artificiales para la predicción de la calidad en soldadura por resistencia por puntos*. *Revista de Metalurgia*. 45, pp. 345-353, 2006.
- [11] Ponce, P., *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega, México, 2012.
- [12] Rosenblatt, F., *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan Books, Washington DC, 1961.
- [13] Rubio, E., Ordoñez, L., Ricalde, L., De La Cruz, E., & Peón, R., *Diseño de una micro red eléctrica inteligente con sistema fotovoltaico y celda de combustible*. *Pistas educativas*. 120, pp. 516-532, 2016.
- [14] Rumelhart, D., Geoffrey, E., & Williams, R., *Learning Internal Representations by Error Propagation*. 1986. David E. Rumelhart, James L. McClelland and the PDP research, 1986.
- [15] Zhang, Q., *Wavelet Network: The Radial Structure and an Efficient Initialization Procedure*. Technical Report of Linköping University. LiTH-ISY-I-1423, 1992.
- [16] Yadav, A. & Chandel, S., *Identification of relevant input variables for prediction of 1-minute time- step photovoltaic module power using artificial neural networks and multiple linear regression models*. *Renewable and Sustainable Energy Reviews*. In press, 2017.