

UNA NUEVA APROXIMACIÓN PARA LA CARACTERIZACIÓN DE MÓDULOS FOTOVOLTAICOS BASADA EN REDES NEURONALES

Por *F. Almonacid, L. Hontoria,
J. Aguilera y G. Nofuentes*

Grupo Investigación y Desarrollo en Energía Solar
y Automática. Dpto. de Ingeniería Electrónica.
E.P.S. Jaén. Universidad de Jaén

RESUMEN

Los módulos fotovoltaicos («PV» a partir de ahora) ofrecen a menudo una potencia menor que la nominal. Esto explica la creciente demanda para realizar un control de calidad de los módulos y asegurar que proporcionarán la potencia deseada. En este artículo se presenta una aplicación, basada en una red neuronal denominada Perceptrón Multicapa, que permite extrapolar la característica I-V de los módulos PV a condiciones estándar (STC). En el proceso de entrenamiento la red neuronal usa pares de datos de entrada / salida. La entradas del entrenamiento son la radiación solar y la temperatura del módulo, mientras que la salida es la característica I-V del módulo fotovoltaico.

Los resultados muestran que la red proporciona una buena aproximación entre los

Summary

Photovoltaics («PV» now on) modules currently available offer an actual power smaller than the nominal value. This explains the recent increased demand on how to check and ensure that PV modules will deliver the expected power. In this paper an application for extrapolating I-V characteristics of PV modules to Standard Test Conditions (STC), based on the neural network called Multi-layer Perceptron (MLP), is presented. The neuronal network receives the solar irradiation and the PV module temperature as inputs, and estimates the I-V characteristics as output. The training process for the neuronal network uses a se-

datos predichos para el módulo PV y los medidos. Por otro lado, se ha llevado a cabo un estudio comparativo con otros métodos de caracterización de módulos PV con objeto de demostrar la validez del método propuesto.

ries of input/output data pair. The training inputs are the solar radiation and the PV module temperature, while the outputs are the I-V characteristics of the PV module.

The results show that, the proposed neuronal network introduces a good accurate prediction for the PV module with the measured values. On the other hand, a comparative study with other characterises photovoltaic modules methods have been done in order to demonstrate the validity of the one proposed.

1. INTRODUCCIÓN

LOS módulos fotovoltaicos («PV» a partir de ahora) proporcionan a menudo un potencia menor que su valor nominal. Esto explica la reciente demanda de métodos que permitan chequear los módulos y asegurar de este modo que suministran la potencia especificada o nominal.

Los fabricantes proporcionan las características de los módulos PV para unas determinadas condiciones, denominadas Condiciones Estándar de Medida (Standard Test Conditions en Inglés: STC). Estas condiciones consisten en una irradiancia de 1.000 W/m², una distribución espectral conforme al espectro AM 1.5 y una temperatura del módulo de 25° C. Sin embargo estas condiciones rara vez ocurren en el exterior. Como consecuencia, estimar el comportamiento eléctrico de un módulo PV, requiere trasladar el comportamiento eléctrico del módulo PV (la denominada curva I-V) medido en cualesquiera condiciones a condiciones estándar de medida (STC). Es po-

sible realizar esta traslación de curvas I-V mediante diferentes métodos numéricos o algebraicos. De entre ellos uno de los más aceptados e importantes es el que denominaremos método de Blaesser [3].

En este artículo, se ha desarrollado una red neuronal denominada Perceptrón Multicapa (PMC) [1, 6, 10, 11, 12], en una arquitectura realimentada para la caracterización eléctrica de un módulo PV y la obtención de curvas I-V del mismo en condiciones STC. Esta red neuronal ya se utilizó en trabajos previos con excelentes resultados [7, 8]. Se ha realizado asimismo un estudio comparativo con los resultados obtenidos por medio de métodos tradicionales en la caracterización eléctrica de módulos. El método que proponemos está basado en la capacidad del PMC de aproximar cualquier función continua definida dentro de un conjunto compacto dentro de un margen de error prescrito [2, 4, 5, 9]. Para conseguir esto es suficiente con emplear un PMC con una capa oculta, un determinado número de neuronas y un adecuado proceso de entrenamiento.

Otro aspecto a destacar en este artículo es la posibilidad de emplear esta arquitectura con un conocimiento reducido del problema a considerar. En este sentido este artículo proporciona una metodología de diseño simple con bastante aplicación general.

El artículo se organiza de la siguiente manera. La primera sección es esta introducción. La sección 2 describe el módulo PV utilizado en este estudio. La sección 3 presenta la estructura general de PMC. En la sección 4 se explica el modelo de PMC utilizada así como el proceso de entrenamiento. Un estudio comparativo con otros métodos ha sido desarrollado en la sección 5. Por último en la sección 6 se presentan las conclusiones y líneas de futuro.

2. MÓDULO PV

El principio físico que rige el comportamiento de una célula fotovoltaica, puede ser explicado tomando como base una unión p-n de un material semiconductor sensible a la luz solar, es decir, el comportamiento eléctrico de una célula PV de x-Si es esencialmente el de un diodo.

Una célula sólo es capaz de proporcionar un voltaje de aproximadamente 0.5 V y una potencia entre 1 W y 2 W. Para aumentar la potencia suministrada, las células se conectan en serie y/o en paralelo. Las células conectadas de esta manera constituyen el denominado módulo fotovoltaico.

La expresión exponencial (ecuación 1) simplificada propuesta por Gow y Manning, recoge la relación que existe entre la tensión (V) y la corriente (I) proporcionada por un módulo:

$$I = n_p \left[I_L - I_s \left[e^{\left(\frac{V}{n_s} + \frac{IR_s}{n_p} \right) / AKT} - 1 \right] - \frac{V/n_s + IR_s/n_p}{R_p} \right] \quad (1)$$

Donde n_p y n_s indican el número de células conectadas en paralelo y en serie; R_p y R_s las resistencias intrínsecas paralelo y serie asociadas a la célula, K es la constante de Boltzmann y q es la carga del electrón. El factor A determina la desviación de la característica de la unión $p-n$ ideal, e I_s es la corriente de saturación, que representa la dependencia del módulo con la temperatura. I_L representa la corriente generada por la radiación solar (S). Existe una dependencia de la corriente con respecto a la radiación y la temperatura.

La expresión anterior (teniendo en cuenta la dependencia de estos parámetros con la temperatura y la radiación), proporciona las denominadas curvas I-V teóricas del módulo fotovoltaico, y el producto de ambas magnitudes proporciona la potencia suministrada. En la figura 1 se muestran las curvas I-V para un determinado módulo a diferentes condiciones de medida.




Figura 1.—Curvas I-V de un módulo específico.

Cada curva presenta un punto de máxima potencia, que es el punto óptimo de operación. El módulo debe trabajar en este punto para un uso eficiente del mismo. Otros dos puntos importantes de esta curva son, el voltaje en circuito abierto (V_{oc}) y la corriente de cortocircuito (I_{sc}). El voltaje en circuito abierto representa el máximo voltaje que proporciona el módulo para corriente cero (sin carga o en vacío), mientras que la corriente de cortocircuito muestra la máxima corriente que es capaz de proporcionar el módulo (carga en cortocircuito). En el estudio que se ha realizado se ha utilizado el módulo I-106 de Isofotón. La tabla I muestra las características de este módulo.

TABLA I

Valores típicos para una radiación de 100 mW/cm², AM 1.5 y una temperatura de la célula de 25° C ($\pm 0.5^\circ$ C)

Especificaciones Eléctricas	I-106
Potencia Máxima (Pmax)	106 W
Corriente de cortocircuito (Isc)	6.54 A
Voltaje de circuito abierto (Voc)	21.6 V
Corriente de máxima potencia (Imax)	6.10 A
Voltaje de máxima potencia (Vmax)	17.4 V

Este módulo fue calibrado por el CIEMAT (Centro de Investigaciones Energéticas Medioambientales y Tecnológicas). El CIEMAT cuenta con un laboratorio independiente y acreditado para la calibración de módulos fotovoltaicos. La potencia máxima proporcionada en condiciones STC es de $96.6 \text{ W} \pm 2.2\%$.

3. REDES NEURONALES: PERCEPTRÓN MULTICAPA

3.1. Definición y descripción de una RNA

Una Red Neuronal Artificial (RNA) es un sistema de procesamiento de información [6] que tiene ciertas características de funcionamiento en común con las redes neuronales biológicas. Las RNAs se han desarrollado como generalizaciones de modelos matemáticos del conocimiento humano o de la biología neuronal, basados en las siguientes suposiciones:

- 1) El procesado de la información ocurre en muchos elementos simples llamados neuronas.
- 2) Las señales pasan entre las neuronas a través de enlaces que las unen.
- 3) Cada conexión entre neuronas lleva asociado un peso, el cual, en una red neuronal típica, lo que hace es multiplicar la señal transmitida.
- 4) Cada neurona aplica una función de activación (generalmente no lineal) a su entrada con el objetivo de determinar su señal de salida.

Una red neuronal se caracteriza por estos tres elementos o características:

- 1) La topología de conexiones entre neuronas, lo que recibe el nombre de *arquitectura* de la red.
- 2) El método de determinación de los pesos sobre las conexiones, denominado *algoritmo de entrenamiento* o de *aprendizaje*.
- 3) La *función de activación* que tengan sus neuronas.

Para comprender un poco mejor por qué estos modelos matemáticos para procesamiento de la información reciben el nombre de redes neuronales, se analizará la estructura de una RNA.

3.2. Redes Neuronales Artificiales

Según la estructura descrita anteriormente se han ideado modelos de neuronas bastante sencillos pero altamente interconectados, formando redes que trabajan paralela y asíncronamente. No obstante no se debe olvidar que un rasgo típico de la modelización es la extracción de características importantes.

Simplificando, se puede decir que la función básica de una neurona es sumar sus entradas y producir una salida si la suma es mayor que un umbral determinado. El tipo (excitatorio o inhibitorio) y la efectividad de estas entradas, es función de la cantidad de señal recibida en las sinapsis, así como el tipo de éstas. La conexión de varias neuronas forma lo que comúnmente se denomina una red de neuronas.

En una red neuronal artificial, la unidad básica, análoga a la neurona biológica se denomina comúnmente *elemento de proceso (EP)*.

En la actualidad, distintos modelos de redes utilizan también distintos modelos de elementos de proceso; sin embargo, se puede establecer un marco general que los describa.

Una red neuronal artificial consiste en varios elementos de proceso conectados de alguna forma, generalmente organizados en grupos denominados *capas*.

En toda red neuronal existen dos capas típicas, que tienen conexión con el exterior; éstas son la *capa de entrada*, a través de la cual los datos son presentados a la red, y la *capa de salida*, la cual muestra la respuesta de la red a una entrada dada. El resto de las capas existentes entre estas dos se denominan *capas ocultas*.

Las RNAs, al igual que las redes de neuronas biológicas, almacenan la información en los pesos asociados a las conexiones entre elementos de proceso. Podría decirse que una red diseñada para un fin específico, consta de un número determinado de elementos de proceso conectados en una estructura concreta y adecuada a tal fin, de unos pesos generalmente fijos en las conexiones entre estos elementos de proceso, y de una dinámica de funcionamiento que permita a la red obtener la salida deseada a una entrada dada.

Esto hace que se puedan estudiar las características principales de una RNA atendiendo a su topología (estructura de la red), su ley de aprendizaje (determinación de los pesos adecuados) y a su dinámica de funcionamiento, además de otras características.

Respecto a la topología de las RNA, la forma simplificada de una red no contiene conexiones hacia atrás («feedback») de unas capas hacia otras, conexiones dentro de la misma capa, ni de un elemento de proceso a sí mismo. Estas redes son llamadas comúnmente *redes alimentadas hacia adelante* o *redes feed-forward*. En este caso, la información pasa de la capa de entrada a través de las capas ocultas hasta la capa de salida de una forma sencilla, usando la suma y la función de activación de la red en particular. A pesar de que su flujo de información es simple, estas redes son interesantes a causa de la no-linealidad en sus transformaciones.

En otras redes, se usa una cierta cantidad de retroalimentación para dar a la red un cierto carácter temporal, o dicho de otra forma, hacer que sea sensible al tiempo. Si existe retroalimentación, la información reverberará alrededor de la red a través de las capas, o dentro de ellas, hasta que se alcance algún criterio de convergencia, momento en el que la información se pasa a la salida.

Actualmente, en distintos modelos de redes coexisten distintos tipos de conexiones llegando en ocasiones a una interconexión total.

Una característica importante de las RNAs es la forma en que almacenan información. La memoria de estas redes es distribuida. Los pesos de las conexiones son las unidades de memoria de la red, y los valores de dichos pesos representan su estado actual de conocimiento. Una unidad de información, representada por un par entrada / salida deseada, es distribuida a través de muchas unidades de memoria en la red y comparte éstas con muchas otras unidades de conocimiento almacenadas en la misma.

El proceso para almacenar la información en los pesos de las conexiones viene dado por lo que comúnmente se conoce como *aprendizaje*. Al contrario de los sistemas expertos donde el conocimiento se da explícitamente por medio de reglas, las RNAs generan su propio conocimiento aprendiendo de ejemplos que le son mostrados. El aprendizaje se consigue a través de reglas que adaptan o cambian los pesos de las conexiones de la red en respuesta a los ejemplos de entrada dados y, opcionalmente, a la salida deseada para esas entradas.

Si la salida deseada es suministrada a la red por un entrenador, se dice que el *aprendizaje es supervisado*. En este caso, para cada estímulo de entrada, se le presenta a la red un estímulo de salida deseado, y ésta se configura a sí misma gradualmente para almacenar la correspondencia entrada / salida deseada.

Por el contrario, si a la red no se le muestra la salida deseada, el aprendizaje se denomina *aprendizaje no supervisado*. En este caso, solamente los estímulos de entrada son mostrados a la red la cual se organiza a sí misma internamente de tal forma que cada elemento de proceso oculto responde muy activamente o muy débilmente a un grupo de estímulos de entrada. Este grupo de estímulos se representa mediante conjuntos en el espacio de entrada, que corresponden a distintos conceptos del mundo real.

Existe un tercer tipo de aprendizaje denominado *aprendizaje por refuerzo*, en el cual un entrenador externo proporciona información parcial a la red, indicando únicamente si su respuesta a una entrada es buena o mala.

Cualquiera que sea el aprendizaje usado, una característica esencial de la red es la *regla de aprendizaje*, la cual indica cómo adaptar los pesos de las conexiones para aprender un ejemplo dado. Por ejemplo, para el modelo de RNA que se utilizará en este proyecto esa regla de aprendizaje (que será explicada y detallada posteriormente) se traduce en el llamado algoritmo de retropropagación (*backpropagation*).

3.3. Usos de las redes neuronales artificiales

Actualmente las redes neuronales han encontrado aplicación en multitud de campos de la ciencia y la ingeniería que van desde el tratamiento de señales hasta los negocios. Se puede afirmar que las redes neuronales son una buena alternativa a gran número de métodos que se aplican en numerosos campos. En la mayoría de los casos, incluso para problemas que se han resuelto por otros medios y gracias a diferentes teorías, las redes neuronales han encontrado a su vez, otras formas de resolución más eficientes.

Como ejemplo se presentan a continuación diferentes campos en los dichas redes se han utilizado:

- Tratamiento de señal.*
- Compresión de datos.*
- Medicina.*
- Reconocimiento del Habla.*
- Aplicaciones económicas y empresariales.*
- Sistemas energéticos. Radiación solar.*

3.4. El Perceptrón Multicapa

De entre los diferentes modelos de RNA que existen, en este trabajo se ha utilizado el llamado perceptrón multicapa (PMC), por lo que en el presente capítulo se describe dicha red neuronal artificial.

3.4.1. El combinador lineal adaptativo

El combinador lineal adaptativo o «neurona artificial» consiste en un elemento cuya salida es una combinación lineal de sus entradas (figura 2). En cada instante k , la salida lineal se calcula como suma ponderada de las entradas $x_k = [x_0, x_{1k}, x_{2k}, \dots, x_{nk}]^T$, es decir, la salida es igual al producto escalar $s_k = x_k^T w_k$. El conjunto de coeficientes $w_k = [w_{0k}, w_{1k}, w_{2k}, \dots, w_{nk}]^T$ se denomina *vector de pesos*. Las componentes del vector de entrada, pueden ser valores analógicos continuos o valores binarios. Los pesos son variables reales que pueden tomar valores tanto positivos como negativos.

Durante el proceso de entrenamiento (aprendizaje), se presentan al combinador lineal los patrones de entrada, x_k , y las respuestas deseadas correspondientes, d_k . El algoritmo de aprendizaje ajusta los pesos de forma que las salidas se aproximen tanto como sea posible a los valores deseados. Un

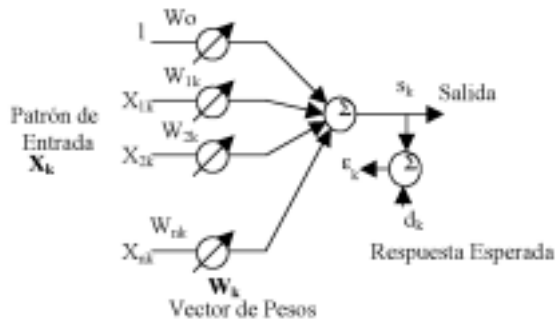


Figura 2.—Combinador Lineal Adaptativo.

método muy empleado para adaptar los pesos es el algoritmo de mínimos cuadrados (α -LMS, «Least Mean Square») también denominado regla delta de Widrow-Hoff.

Este algoritmo minimiza la suma de los cuadrados de los errores lineales del conjunto de entrenamiento. El error lineal ϵ_k se define como la diferencia entre la respuesta deseada y la salida en el instante k , o sea $\epsilon_k = d_k - s_k$. Esta señal de error es necesaria para adaptar los pesos.

3.4.2. El Perceptrón

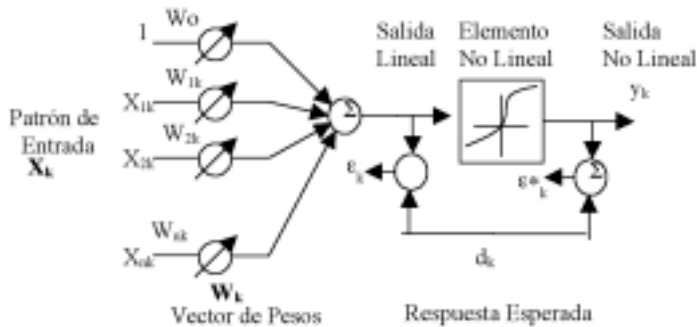
El elemento constitutivo básico utilizado en muchas redes neuronales, es el *Perceptrón*. Consiste en un combinador lineal adaptativo seguido de un elemento no lineal (figura 3). En esa figura el error lineal es ϵ_k y el error en la salida no lineal es ϵ^*_k , siendo sus expresiones:

$$\epsilon_k = d_k - s_k, \quad \epsilon^*_k = d_k - y_k$$

Existen tres tipos comunes de no linealidades: los cuantizadores (función signo), los elementos con umbrales de saturación y las no linealidades de tipo sigmoideal.

3.4.3. El perceptrón multicapa

Minsky y Papert (1969) [13], realizaron un estudio detallado de los tipos de representaciones posibles con el perceptrón, y demostraron que, en un gran número de casos, estos tipos de redes son incapaces de resolver los problemas de clasificación. Sin embargo demostraron que un perceptrón constituido por *varias capas*, puede realizar cualquier aplicación desde las capas de entrada a las de salida. El inconveniente que se tenía en estos primeros



Tipos de no linealidades




Figura 3.-Perceptrón y no-linealidades.

estadios del manejo del perceptrón, era el desconocimiento de un algoritmo de entrenamiento eficiente para redes con más de una capa.

El perceptrón multicapa es una red acíclica de propagación directa con una o más capas de nodos entre las entradas y las salidas. Estas capas adicionales contienen nodos denominados *ocultos*, ya que no son visibles directamente ni desde las entradas, ni desde las salidas.

3.5. Aplicación del PMC

En primer lugar las curvas I-V deben ser tratadas como función de dos parámetros: irradiancia (G) y temperatura del módulo (T_c). Considerando una función general (H) que relaciona los dos parámetros mencionados, el problema se reduce a la computación de la función H . El PMC aproxima la función haciendo uso de los datos disponibles (curvas I-V para cada valor

de G y T_c). Por lo tanto, el procedimiento de predicción depende de la posibilidad de entrenar la red tal que:

$$(I, V) = H(G, T_c) \quad (2)$$

Entrenando la red con dos entradas y una salida, mediante un conjunto de datos suficientemente representativo, el PMC es capaz de encontrar los valores deseados mediante la aproximación de la función H . Una vez entrenada la red, se pueden calcular las curvas I-V para cualquier valor de irradiancia y temperatura del módulo.

4. MÉTODO PROPUESTO

4.1. Arquitectura del PMC

Un método de caracterización de módulos PV basado en el PMC tiene la cualidad de que la mayor parte de la carga computacional recae en el entrenamiento y no en la generación de las curvas. Además, una vez desarrollado un método a partir de datos para un determinado módulo (curvas I-V para una irradiancia y temperatura del módulo), se podrá aplicar para otros módulos sin más que repetir el entrenamiento con los datos correspondientes al nuevo módulo.

La estructura de PMC propuesta para la generación de curvas I-V se muestra en la figura 4 consiste en tres capas. La primera capa tiene como entradas las descritas anteriormente (radiación y temperatura del módulo):

La segunda capa, tiene en este caso tres neuronas. Diferentes pruebas realizadas dan como tres el número de neuronas que producen el mejor resultado. Finalmente la capa de salida tiene los valores I-V de la curva a generar.

El entrenamiento se realiza mediante el algoritmo de retropropagación Levenberg-Marquardt. Existen varios algoritmos característicos, en general, para problemas de funciones de aproximación, en redes que contienen unos




Figura 4.—Arquitectura del PMC para obtener curvas I-V.

pocos cientos de pesos, siendo este algoritmo es el que produce una convergencia más rápida.

4.2. Datos Disponibles

Como se ha descrito anteriormente el objetivo de este proyecto es diseñar un PMC con la estructura descrita en la sección anterior. El PMC genera curvas I-V para cada valor de irradiancia (G) y temperatura del módulo (T_c) en estudio. El PMC debe ser entrenado con datos para varias radiaciones y temperatura de módulo de las que se tiene su curva I-V y después validado para otros valores de irradiancia y temperatura. En la siguiente tabla se muestran los valores de irradiancia y temperatura del módulo usados para este estudio.

TABLA II
Datos usados en el entrenamiento

Irradiancia (wm^{-2})	Temperatura Ambiente	
716	29.1	T
601	24.9	T
1001	19.8	T
1018	28.6	T
728	27.9	T
1108	34.1	T
979	21.5	V
1001	19.8	V
717	29.0	V
1114	37.0	V

Como puede observarse en la tabla, los datos elegidos tienen diferentes valores. En la última columna se indica el uso del dato. La letra «T» indica que el dato se ha utilizado para el entrenamiento del PMC, y «V» para la validación del PMC después del entrenamiento.

El método propuesto y el proceso de validación puede resumirse de la siguiente manera:

Paso 1.–Obtención de las curvas I-V reales para cada G y Tc

En primer lugar, las curvas I-V son obtenidas a sol real mediante una carga comercial electrónica. Esta carga comercial es el *Photovoltaik Engineering, Peak Power Measuring Device for PV-Modules*, abreviadamente PVPM2540C. Esta carga permite realizar medidas de las curvas I-V de módulos y generadores fotovoltaicos, dando información de las características eléctricas de los mismos.

Funciona con una batería recargable, que permite realizar medidas en lugares sin conexión a red. Las medidas recogidas son almacenadas en una memoria interna, para volcarlas posteriormente a un ordenador, o bien se puede trabajar conectado al ordenador guardando las medidas directamente en la memoria del PC.

Con estos resultados el dispositivo puede calcular la potencia de pico del módulo directamente del lugar de instalación. Además, el PVPM 2540C mide la irradiancia (G) y la temperatura del módulo (Tc) a través de un sensor Phox100/pt100 situado cerca del módulo a medir. Este sensor debe tener exactamente la misma orientación del módulo.

Paso 2.–Entrenamiento del PMC

A continuación, se lleva a cabo el entrenamiento del PMC. Para el proceso de entrenamiento, el PMC recibe información de las curvas I-V reales obtenidas anteriormente, pero sólo de las seis primeras filas de la tabla (aquellas designadas con la letra «T»).

Paso 3.–Generación de las curvas I-V y validación del PMC

Por último, una vez que el PMC está entrenado se realiza la generación de las curvas I-V para los valores de las últimas cuatro filas de la tabla (aquellos marcados con la letra «V»). Las curvas I-V obtenidas se comparan con las curvas reales obtenidas en el paso 1.

En la siguiente sección se muestran los resultados obtenidos.

5. RESULTADOS

Aplicando la metodología explicada anteriormente se han obtenido diferentes curvas I-V de un módulo PV, en particular la curva I-V de módulo PV en condiciones estándar. Como se mencionó anteriormente la generación de curvas I-V no sólo se ha realizado para los valores de irradiancia y tem-

peratura del módulo usados para el entrenamiento, sino también para aquellos usados en la validación.

Como medida de calidad se ha calculado el error cuadrático medio (RMSE) y el error medio (MBE), entre las curvas reales y aquellas obtenidas mediante el PMC.

5.1. Error Cuadrático Medio RMSE (Root Mean Square Error)

El error cuadrático medio, también conocido como la raíz cuadrada del error cuadrático medio (en inglés Root Mean Square Error = RMSE), ha sido utilizada en este trabajo para contrastar en qué medida los valores predichos se acercan a los valores observados. Las fórmulas adaptadas al caso que nos ocupa son:

$$RMSE_p = \sqrt{\frac{\sum_{i=1}^N (P_{Ti} - P_{Oi})^2}{N}} \quad (W) \quad (3)$$

donde:

P_{Ti} = Potencia predicha o teórica.

P_{Oi} = Potencia medida u observada.

N = Número de muestras.

$RMSE_p$ = RMSE entre la potencia observada y la teórica en W .

5.2. Error Medio MBE (Mean Bias Error)

El error medio (en inglés Mean Bias Error = MBE), conocido como sesgo o desviación, ha sido utilizado en este trabajo junto con el RMSE para caracterizar la bondad de cada uno de los métodos sometidos a estudio. Puesto que las medidas recogidas se realizan para ciertos intervalos de tiempo, el MBE será la media de todas las medidas realizadas. Las fórmulas adaptadas al caso que nos ocupa son:

$$MBE_p = \frac{\sum_{i=1}^N (P_{Ti} - P_{Oi})}{N} \quad (W) \quad (4)$$

donde:

MBE_p = MBE de la entre la potencia observada y la teórica en W .

En la figura 5 se muestran algunos ejemplos de curvas generadas mediante el PMC




Figura 5.—Curvas I-V obtenidas para diferentes radiaciones y temperaturas del módulo.

Como se observa en la figura 5, puede deducirse que las curvas I-V obtenidas mediante el PMC son muy parecidas a las curvas I-V reales obtenidas mediante el PVPM 2540C. Es importante resaltar la capacidad del PMC de generar curvas para valores distintos de los del conjunto de entrenamiento. Esto indica que cualquier curva generada por el PMC asegura que sus resultados serán muy similares a los reales.

Se ha calculado tanto el *Root Mean Square Error* (RMSE) como el *Mean Bias Error* (MBE) entre la curva real y la proporcionada por el PMC, mostrándose el resultado en la tabla III. Se debe recordar que los datos de las seis primeras filas se han usado para el entrenamiento del PMC, pero los de las cuatro últimas filas no.

Se observa que el RMSE (igual que el MBE) es pequeño, lo que indica una buena aproximación entre ambas curvas (la real y la proporcionada por el PMC) para cada irradiancia y temperatura del módulo. Sólo para los últimos valores es mayor. Lo que es lógico ya que estos datos no han sido em-

TABLA III

RMSE y MBE entre las curvas reales y las obtenidas con el PMC

Irradiancia (W/m. ²)	Temperatura Ambiente	RMSE	MBE
716	29.1	0.6281	-0.2165
601	24.9	0.3755	0.1522
1.001	19.8	0.7187	0.2354
1.018	28.6	0.1103	0.0194
728	27.9	0.1251	-0.0722
1.108	34.1	0.2954	-0.1193
979	21.5	1.0515	0.4449
1.001	19.8	0.7187	0.2354
717	29.0	0.6308	-0.1699
1.114	37.0	1.0340	0.6588

pleados en el proceso de entrenamiento del PMC. Además la aproximación entre la curva real y la del PMC es muy buena.

Una vez verificada la validez del método propuesto, obtenemos la curva I-V del módulo en condiciones STC. A continuación se comparará esta curva con la proporcionada por el fabricante, la calculada mediante el método Blaesser [3], la que proporciona el PVPM 2540C y la que da el CIEMAT.

5.3. Determinación de la característica I-V mediante el método Blaesser [3]

El procedimiento para la determinación de la característica I-V es el siguiente:

1. Durante el día hacer repetidas medidas de voltaje en circuito abierto (V_{oc}) para un amplio rango de niveles de irradiancia, en particular para niveles de baja radiación (100-300 W/m.²). La temperatura ambiente T_{am} y la irradiancia G_1 asociada a cada valor V_{oc} , deben, también, ser medidos.

2. Para este conjunto de datos (V_{oc} , T_{am} , G_I) se determina el valor de V_{oc} en condiciones estándar ($V_{oc, STC}$) usando la fórmula:

$$\begin{aligned} V_{oc, STC} &= V_{oc} (1 + DV) \\ DV &= a \ln(G_{STC} / G_I) + b(T_{am} - T_{STC}) + cG_I \end{aligned} \quad (5)$$

Los coeficientes a , b y c deben elegirse de forma que se minimice la «Desviación estándar» de los valores $V_{oc, STC}$ resultantes. Puede comenzarse con las siguientes estimaciones:

$$a = 0.06, \quad b = 0.004 [^{\circ}C], \quad c = 0.12 [m^2 / kW] \quad (6)$$

El valor final de $V_{oc, STC}$ se obtiene como la media de los valores derivados de las medidas individuales.

3. Obtener la curva I-V por medio de una carga, grabando simultáneamente el valor de G_I . Cuando se usa una carga rápida (el caso de una carga capacitiva) el tiempo de escaneo debe estar dentro del rango de 20 y 200 ms y el número de puntos de la curva I-V debe ser de al menos 50.

4. Extrapolar la característica I-V medida a condiciones estándar transformando cada punto de la curva (I, V) en su correspondiente (I_{STC} , V_{STC}) mediante las fórmulas:

$$\begin{aligned} I_{STC} &= I(G_{STC} / G_I) \\ V_{STC} &= V + DV - R_s(I_{STC} - I) \end{aligned} \quad (7)$$

donde:

$DV = V_{oc, STC} - V_{oc}$ la diferencia entre el valor de V_{oc} obtenido durante el escaneo y el determinado por el método descrito arriba,

R_s es la resistencia del módulo y del cableado; se calcula midiendo la característica I-V del módulo para dos irradiancias. Una para baja radiación alrededor de 600 W/m^2 y otra para alta radiación alrededor de 1000 W/m^2 . Ambas curvas se trasladan a condiciones STC usando un valor de $r = R_s \cdot I_{sc, STC} / V_{oc, STC}$ dentro del rango 0 y 0.1 hasta que el valor encuentre el mejor resultado entre las curvas, es decir, cuando las dos curvas trasladadas a condiciones STC sean la más parecidas.

Una vez obtenida la curva I-V en condiciones STC mediante el método Blaesser la comparamos con la obtenida mediante el PMC, y también con la proporcionada por el fabricante y el CIEMAT

La figura 6 muestra la característica I-V del módulo en condiciones estándar obtenida mediante los distintos métodos:




Figura 6.–Curvas I-V obtenidas mediante diferentes métodos.

La tabla IV muestra los valores de potencia máxima, $V_{oc, STC}$ y $I_{oc, STC}$, obtenidos con cada método.

TABLA IV

P_{max} , $V_{oc, STC}$ y $I_{sc, STC}$ obtenidos con cada método

	P_{max} (W)	$V_{oc, STC}$ (V)	$I_{sc, STC}$ (A)
PMC	94.63	21.23	6.43
Blaesser	93.59	20.42	6.55
PVPM	92.77	21.50	6.54
Fabricante	106.13	21.60	6.10
CIEMAT	96.6	21.39	6.42

Como puede verse en la tabla anterior, los datos obtenidos mediante el PMC son muy similares a los proporcionados por el CIEMAT para este módulo. Puede verse también como los datos proporcionados por el fabricante para este módulo difieren bastante de los medidos por el CIEMAT.

Considerando la curva proporcionada por el CIEMAT como la real, calculamos el RMSE y el MBE para cada método (comparando con la curva del CIEMAT):

TABLA V
RMSE y MBE para cada método

	RMSE	MBE
PMC	1.4293	-0.1027
Blaesser	13.2025	-4.2815
Fabricante	10.4141	5.8614
PPVPM	1.2760	-0.3377

Puede verse que el error es bajo lo que indica una buena aproximación entre la curva PMC y la proporcionada por el CIEMAT.

6. CONCLUSIONES Y LÍNEAS DE FUTURO

Se ha presentado un método basado en redes neuronales artificiales para la generación de curvas I-V. Este método permite el paso de curvas I-V medidas en condiciones cualesquiera a condiciones estándar de una forma sencilla y a la vez precisa. Se evitan de este modo el uso de métodos matemáticos complicados.

Se ha validado el método propuesto comparando las curvas I-V obtenidas por diferentes métodos con a las curvas I-V generadas por el PMC. Tras el estudio comparativo se observa que tanto cualitativamente (gráficas I-V muy similares) como cuantitativamente (errores RMSE y MBE muy bajos) el método propuesto es una herramienta muy útil.

Asimismo, el método basado en redes neuronales desarrollado puede ser un primer paso para la caracterización de generadores fotovoltaicos.

Esta herramienta también podrá ser aplicada no sólo para la caracterización de módulos fotovoltaicos, sino para otros componentes de sistemas fotovoltaicos como pueden ser baterías, reguladores, etc.

REFERENCIAS:

- [1] M. AGARWAL: «A Systematic Classification of Neural-Network-Based Control». *IEEE Control Systems Magazine*, vol. 17, No. 2, págs. 75-93, April 1997.
- [2] A. R. BARRON: «Universal approximation bounds for superpositions of a sigmoidal function», *IEEE Trans. Inform. Theory*, vol. 39, págs. 930-945, 1993.
- [3] COMMISSION OF THE EUROPEAN COMMUNITIES, JOINT RESEARCH CENTRE OF ISPRA: *Guidelines for the Assessment of Photovoltaic Plants*, Document C, Issue 4.1, 1993.
- [4] G. CYBENKO: «Approximation by superpositions of a sigmoidal function». *Math. Contr., Signals, Syst.*, vol. 2, págs. 303-314, 1989.
- [5] K. FUNAHASHI: *On the approximate realisation of continuous mappings by neural networks*, Neural Networks, vol. 2, págs. 183-192, 1989.
- [6] S. HAYKIN: *Neural Networks. A Comprehensive Foundation*. Macmillan Publishing Company, 1994.
- [7] HONTORIA, L.; AGUILERA, J.; ZUFÍRIA P.: *Generation of hourly irradiation synthetic series using the neural network multilayer perceptron*. Solar Energy Vol.: 72 págs. 441- 446 Date: 2002 Ed. Pergamon.
- [8] HONTORIA, L.; AGUILERA, J.; RIESCO, J.; ZUFÍRIA, P.: «Recurrent neural supervised models for generating solar radiation synthetic series». *Journal of Intelligent and Robotic Systems*, vol. 31 págs. 201-221 Date: 2001 Ed.: Kluwer Academic Press.
- [9] K. HORNİK, M.; STINCHCOMBE and H. WHITE: «Multilayer Feedforward Networks Are Universal Approximators». *Neural Networks*, vol. 2, no. 5, págs. 359-366, 1989.
- [10] D. R. HUSH and B. G. HORNE: «Progress in Supervised Neural Networks. What's New Since Lippmann». *IEEE S.P. Magazine*, págs. 8-39, January 1993.
- [11] T. KOHONEN: *Self-Organising Maps*. Springer Verlag, Berlin Heidelberg, 1995.
- [12] R. P. LIPPMANN: «An Introduction to Computing with Neural Nets». *IEEE ASSP Magazine*, págs. 4-22, April 1987.
- [13] MINSKY, M. & PAPERT, S.: *Perceptrons: an introduction to computational geometry*. The MIT Press. Cambridge, MA. 1969.

RESEÑA DE LIBROS
