

05-005

IMPROVING ENERGY EFFICIENCY OF PHOTOVOLTAIC PLANT WITH USING ARTIFICIAL NEURAL NETWORKS

Ferrero Bermejo, Jesús; Gómez Fernández, Juan Francisco; Crespo Márquez, Adolfo
Escuela Técnica Superior de Ingenieros de Sevilla, Universidad de Sevilla

The scope of this project is obtaining an ideal electrical power generation model based on artificial neural networks with back-propagation, of a 6,1 MWp photovoltaic power plant located in Cordoba (Spain) operating since september of 2008. The aforementioned model is used with several objectives focusing in efficient energy improvement. With this aim in mind, a critical analysis and warning settlement policy in a SCADA system are developed, in a way that it is possible to anticipate the failure event, comparing the output of the model with the actual power generation. It has been tested the methodology on an specific failure mode to analyze the goodness of the model, reaching a 1,8 % improvement in electrical power production.

Keywords: *energy Efficiency; renewable energy; neural Networks*

MEJORA DE LA EFICIENCIA ENERGÉTICA DE UNA PLANTA FOTOVOLTÁICA CON EL USO DE REDES NEURONALES ARTIFICIALES.

El objeto del presente Proyecto consiste en la obtención del modelo ideal de Producción de una Planta (en ausencia de Fallos) Fotovoltaica de 6,1 MW en Producción desde Septiembre del 2008, ubicada en la provincia de Córdoba. Para la Obtención del Modelo Ideal de Producción nos basamos en la utilización de Redes Neuronales Artificiales, en concreto la Red Backpropagation con variables meteorológicas y variables que controlan los activos. Dicho modelo es utilizado para la obtención de diversos objetivos, de los cuáles nos centramos en la mejora de la eficiencia energética de la instalación objeto de estudio. Para ello definimos un análisis de criticidad y una condición de alarma a implementar en el Sistema de Monitorización de la Planta, de modo que nos permita anticiparnos al fallo con la detección temprana de la degradación en la producción, a través de la comparación del Modelo Ideal obtenido con la producción real. Definimos una metodología para la obtención de fallos con ciertas premisas, con la que finalmente verificamos a través de un fallo particular su eficacia, obteniendo en este caso concreto una mejora estimada en la producción de un 1,8% que dado el volumen de inversión es una cantidad muy considerable.

Palabras clave: *Eficiencia Energética; Energías Renovables; Redes Neuronales*

Correspondencia: Jesús Ferrero Bermejo jesus.ferrero@magtel.es

Agradecimientos: A mi familia. A mis tutores.

1. Contenido.

1.1 Introducción.

El mantenimiento de cualquier equipo cada día cobra más importancia en las empresas, pues todas ellas están orientadas a ofrecer servicios a clientes. No solo es importante el hecho de que un activo tenga una larga durabilidad para amortizar su inversión, sino que cobra mucha más importancia el hecho de que no se produzcan averías y que funcionen a pleno rendimiento en todo momento.

Ello nos lleva a considerar no solo los mantenimientos clásicos de equipos sino que asume una especial relevancia el prevenir fallos, de ahí el auge dentro del mantenimiento del uso de técnicas predictivas que eviten este tipo de paradas o cortes de servicios tan costosos. Por tanto sería muy interesante el poder conocer la predicción futura de producción de dicha empresa sea el producto final que sea. En el presente trabajo pretendemos conocer la predicción de producción de Energía Eléctrica de una planta fotovoltaica de 6,1 Mw ubicada en el término municipal de Fuente Palmera, provincia de Córdoba.

El Mantenimiento Centrado en la Fiabilidad (RCM) es la metodología más utilizada para estudiar los programas de mantenimientos de activos en un contexto operacional dado (Moubray 1997), la cuantificación de los riesgos (Rausand y Hoyland 2004, Wilson 1986) y la evaluación de las medidas correctivas para detectar, evitar o prevenir fallos (Campbell y Jardine 2001). Atribuibles a las condiciones de funcionamiento son las condiciones del contorno y los factores ambientales junto con los de la propia operación. Igualmente inciden en los posibles fallos los defectos propios ocultos de los activos (Crespo 2007; Pham y Wang, 1996).

Para la resolución del problema inicialmente se plantean dos posibles escenarios.

El primero de ellos consiste en la predicción de la producción a través de un modelo tradicional de regresión estadística, el cual nos proporcionaría una ecuación matemática. Dicho método es descartado al no existir relación entre las variables de entrada y salida del modelo planteado.

El segundo de ellos consiste en la resolución del problema a través del uso de Redes Neuronales Artificiales. Esta es la técnica seleccionada para la resolución del caso en la presente comunicación. La arquitectura de las RNA está compuesta por diferentes capas (entrada, ocultas y salida) cuya principal característica es la capacidad de procesar la información en entornos no lineales, con la capacidad de aprendizaje y generalización (Basheer y Hajmeer 2000; Zhang et al 1998). Por ello, las RNA son muy adecuadas para la resolución de problemas de difícil solución con falta de suficientes datos para ello (Malcolm et al. 1999, Curry et al. 2000, Kuo 2011). La aplicación de estas técnicas de utilización de RNA en el sector de las energías renovables, y más en concretos en el sector de los sistemas fotovoltaicos han estado desarrollándose continuamente en los últimos años (Mellit y Kalogirou 2008; Kalogirou 2001):

- Meteorological data forecasting (Mellit et al. 2005; Yacef 2012).
- PV systems modelling, simulation and control (Hiyama 1997).

1.2 Caso de Estudio

El grupo de empresas Magtel al cual pertenezco, es propietario entre otras de una Instalación Fotovoltaica de 6,1Mw de potencia nominal ubicada en el término municipal de Fuente Palmera, provincia de Córdoba. Dicha instalación se encuentra a pleno rendimiento desde Septiembre del año 2008, lo que implica que disponemos de suficiente información y datos recogidos para poder tener capacidad de analizarlos. Esta es la base fundamental para poder realizar el estudio objeto del presente trabajo. Toda la información recogida queda registrada en el Scada de la Instalación Fotovoltaica, del que hemos obtenido todos los datos necesarios de las variables analizadas.

Figura 1. Imagen Aérea Instalación Fotovoltaica objeto de Estudio.



La Instalación Fotovoltaica tal y como hemos indicado tiene una potencia nominal de 6,1 Mw que se encuentran repartidos en huertos solares de 100 Kw. La planta dispone de un total de 37.180 paneles fotovoltaicos de diferentes potencias configurados en función de cada uno de dichos huertos.

Cada uno de estos huertos solares está configurado en torno a un inversor, el cual convierte la corriente continua en alterna para finalmente poder verter la energía generada en un centro de transformación que en este caso ya sería propiedad de la compañía eléctrica y es en el que se mide la energía generada con contadores por cada uno de los huertos solares. Un centro de transformación recoge la energía de un máximo de 5 inversores, siendo la configuración estándar de uno de esos centros de transformación la que se describe a continuación:

Tabla 1: Configuración Estándar de un Centro de Transformación

CT	ID	KWh	Ref Módulo	Nº Módulos	Nº String	Módulos x String
15	A8-1	100	IS-220	528	44	12
	A8-2	100	IS-220	528	44	12
	A8-3	100	IS-220	528	44	12
	A8-4	100	IS-220	528	44	12
	A8-5	100	IS-220	528	44	12

Dichos huertos fotovoltaicos generan anualmente (datos del año 2012) una media de 210.000 Kwh/año según radiación solar de la zona en la que se encuentra y considerando la degradación de dichas instalaciones. El precio de venta de un Kwh es de 0.4886 € (como dato de referencia para el estudio pues la prima depende del año), lo que supone una generación económica anual de cada uno de estos huertos de 100 Kw de 102.606 €, lo que multiplicado por 61 instalaciones de esta Planta en concreto supone una generación en venta de energía anual de 6.258.966 €.

1.3 Objetivos.

El Objetivo general del estudio es del PREDECIR LA PRODUCCIÓN DE ENERGÍA ELÉCTRICA DE UNA INSTALACIÓN FOTOVOLTAICA, obteniendo un modelo ideal de producción. El modelo ideal de producción será obtenido utilizando como datos para el aprendizaje de la Red Neuronal Artificial seleccionada los datos históricos de producción de la planta. Existen trabajos previos a este trabajo en los que se intenta pronosticar la producción de la energía eléctrica generada por una instalación fotovoltaica a través de RNA (Ashraf y Chandra 2004; Mellit y Shaari 2009), sin embargo en este Proyecto se describe un nuevo algoritmo para la detección temprana de fallos.

Para ello centraremos el estudio en un huerto solar de 100 kw tipo en el que existen sensores instalados, que nos han permitido obtener en el Scada todos los valores de las variables de entrada del modelo que posteriormente definiremos. El modelo de producción obtenido se considera ideal debido a que es un modelo de producción en ausencia de fallo.

El objetivo específico es la utilización del Modelo Ideal de Producción para la obtención de conclusiones particulares que permitan obtener mejoras en la producción de la planta fotovoltaica. En sí la búsqueda de dichos objetivos es la parte más interesante, en el sentido de que es una nueva aportación al conocimiento a través del uso de técnicas novedosas.

Algunos de los objetivos específicos que podríamos obtener a través del conocimiento del Modelo Ideal de Producción son los siguientes: Mejora de la Eficiencia Energética, Generalización a cualquier Instalación Fotovoltaica, Generalización del Modelo a multitud de procesos industriales, Creación de Algoritmo para la detección de Fallos con degradación en la producción previa a la detección del fallo por el Scada, Aplicación en la mejora del Mantenimiento, Mejora del Modelo de Negocio con la previsión de resultados económicos según el modelo Ideal de Producción, Mejora económica al obtener mayor producción, Anticipación a fallos, Validación de la detección de alarmas del sistema de monitorización de la Planta.

Puesto que los objetivos específicos son muchos, nos vamos a centrar en uno de ellos a través del cual se pueden deducir otros de los considerados. El Objetivo específico en el que nos vamos a centrar es en el de la MEJORA DE LA EFICIENCIA ENERGÉTICA DE LA PLANTA. Para ello compararemos el Modelo Ideal de Producción obtenido con la producción real lo que nos permitirá detectar desviaciones significativas en la producción para poder anticiparnos a fallos en la planta, con la generación de alarmas que activarán al personal de mantenimiento para la resolución de dicho fallo. Ello evitará la pérdida de producción en un número determinado de horas según el fallo lo que redundará en una mayor generación económica.

Finalmente, podremos modelar fallos y en concreto nos centraremos en uno de ellos a modo de ejemplo genérico, obteniendo datos concretos sobre ganancia en la producción con la implantación de este método.

La detección temprana de fallos supondrá un adelanto en la detección del fallo sobre la alarma que produce el sistema de monitorización de la planta. Por ello todo fallo detectado en el mismo momento por el Scada y por nuestro sistema es descartado para el estudio, puesto que no supondría ventaja alguna sobre el sistema utilizado en la actualidad. La dificultad de este apartado radica por tanto en poder detectar algún fallo que produzca pérdida en la producción de al menos un Huerto Solar (100 Kw) sin que por ello se produzca la alarma en el Scada hasta pasado al menos algún tiempo considerable (en nuestro caso consideramos dicho período como un mínimo de 24 horas de anticipación), de modo que efectivamente con la detección temprana de dicha caída en la producción detectemos anomalías y por tanto podamos reparar con la ganancia de tiempo y producción.

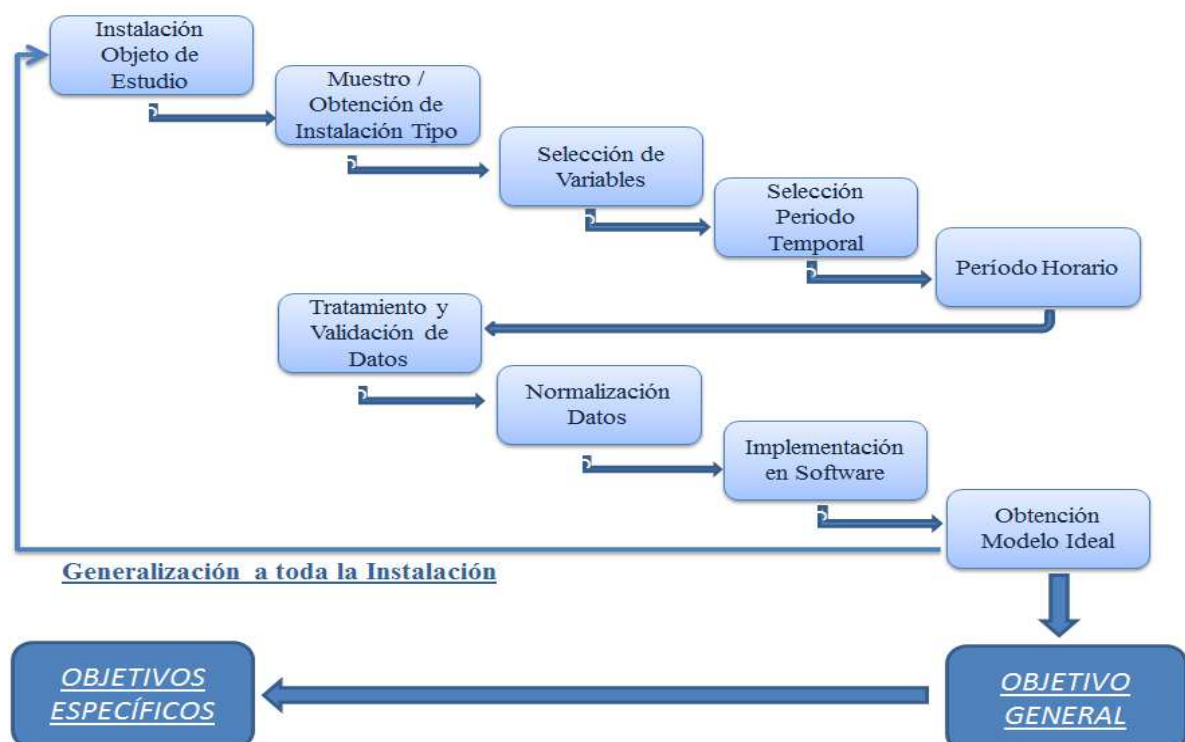
El fallo no sólo debe ser seleccionado sino que además para darlo como válido tendrá que producirse en diversos inversores y en diferentes ocasiones puesto que un fallo puntual no volverá a repetirse y por tanto tampoco podrá volver a ser detectado. Se trata de que la conclusión obtenida sea implantada de modo real en la Instalación Fotovoltaica con objeto de que una vez probado en dicha Instalación y verificada su validez el estudio sea ampliado a todas las plantas que actualmente son mantenidas por la empresa.

Seleccionado al menos uno de esos fallos podremos modelarlo, de modo que suponga para nuestro sistema una mejora en la eficiencia de la producción. Finalmente con el sistema de alarma que definiremos, de producirse la alarma y su correspondiente resolución de la avería a través de los técnicos de mantenimiento, podremos garantizar que se mejora la producción al adelantarnos al fallo pero no podremos concluir que sea un fallo determinado el que iba a producirse con la alarma producida con el sistema implantado

1.4 Metodología.

En la siguiente figura expresamos la metodología empleada, incluyendo todos los pasos necesarios para la obtención de los objetivos planteados.

Figura 2. Metodología



Una vez obtenidos los datos y tratados, la implementación en el software para la obtención del modelo ideal de producción se realiza utilizando Las Redes Neuronales Artificiales, las cuales se adaptan bien a ciertos patrones de comportamiento que no son modelables por otras técnicas matemáticas debido a la variación existente entre las variables de entrada y las variables de salida. Además son modelos adaptables en función del entrenamiento que hace que la red mejore y se adapte mucho mejor, y en nuestro caso particular muy aplicable como veremos en los resultados obtenidos, entre otros porque tenemos un importante histórico de datos filtrados que permite a la red disponer de una importante entrada de valores para que esté bien entrenada.

Dentro del conjunto de RNA existentes, la red seleccionada e implementada en el software es la Red Backpropagation (Hastie et al 2001; Rutkowski 2008; Lapedes y Farber 1987) debido a que es la red más adecuada para la predicción de valores en función de datos históricos conocidos, no siendo más que un mecanismo de aprendizaje de una Red Perceptron Multicapa (Wervos 1974; Rumelhart et al 1986;).

Una vez seleccionada la red es entrenada con el conjunto de datos seleccionados y tratados. Se pretende que el valor o salida obtenida con la red sea lo más cercana posible a la salida real o deseada, por lo que dichas diferencias son las que marcan la parada del algoritmo de entrenamiento, ya que los métodos utilizados son heurísticos al no existir uno óptimo. El método utilizado para la minimización del Error Cuadrático Medio es el método de Cuasi-Newton al que le incluiremos un sumando de penalización para evitar el sobreajuste.

$$\text{ECM} + \text{Penalización} = \frac{1}{n} \sum_{i=1}^n (T_k - Z_k)^2 + \gamma \sum_{i=1}^M w_i^2 \quad (1)$$

Siendo T_k la salida real o deseada, Z_k la salida calculada y w_{ji}^0 el peso de la unión de la neurona i -ésima de la red neuronal con la neurona j -ésima.

Se dice que existe sobreajuste en la red cuando el ajuste es tan bueno que perdemos capacidad de generalización. Este fenómeno ocurre habitualmente cuando estamos intentando simular un patrón de comportamiento con muy pocos valores, por lo que la red lo que intenta es ajustar tanto que se aprende de memoria el patrón repitiendo los valores en las circunstancias futuras análogas. De ahí el perder generalización y el incluir el factor de penalización.

En el caso de que el conjunto de datos del que dispongamos para entrenar la red sea lo suficientemente grande y la variabilidad entre los resultados o salidas sea lo suficientemente importante, lo lógico es que el factor de penalización sea cero a la hora de resolver el problema puesto que dicho patrón no es posible memorizarlo al existir disparidad de resultados. En el caso particular de estudio es lo que sucederá como veremos más adelante. Existen varios métodos para la minimización del ECM, ninguno de ellos obtiene con garantías el mínimo global por lo que dentro de los más reconocidos el motivo por el cual he seleccionado este método no es otro que el que utiliza el software elegido para la resolución del algoritmo. Es decir, utilizamos el método de Cuasi-Newton con factor de penalización y software R.

Con la Red Neuronal Backpropagation y el algoritmo de minimización del error cuadrático medio de cuasi-newton al que aplicaremos en el software R un coeficiente de penalización para evitar los sobreajustes, vamos a entrenar la red en ausencia de fallos obteniendo un modelo ideal de producción. Dicho modelo Ideal es el Objetivo General que pretendíamos alcanzar en el presente estudio, modelo que utilizaremos en la siguiente fase con objeto de mejorar la eficiencia en la producción de la planta, como el principal de los objetivos específicos que pretendemos alcanzar. El modelo ideal de producción vendrá determinado por la Red Neuronal Artificial, la cual

contendrá exactamente un número de células concreto en la capa oculta así como conoceremos los pesos de todas las conexiones existentes entre todas las neuronas de las diferentes capas que configurarán la red. Dicho modelo quedará almacenado para posteriormente predecir valores de producción en función de los valores de entrada que le demos a la red.

1.5 Datos.

Expuesta la metodología para la solución del problema planteado, a continuación aportamos los datos considerados para el entrenamiento de la red.

Instalación Objeto de Estudio: Planta Fotovoltaica 6.1 Mw en la provincia de Córdoba.

Instalación Tipo para Estudio: Inversor 5 del Centro de Transformación 15.

Variables de Entrada: Radiación Global Horizontal, Temperatura Ambiente, Temperatura Interna del Inversor (control de activos), Horas de Funcionamiento acumuladas (control de la degradación).

Periodo Temporal: datos de producción de Junio del 2011 a Julio de 2012. Es decir, tratamos 395 días para disponer de un ciclo completo de producción repitiendo el primer mes del siguiente año. Lo que supone que para el entrenamiento de la red disponemos de 3950 valores por cada variable de entrada, valor suficientemente importante para que la red esté muy bien entrenada. Nos aporta garantía a la hora de obtener el modelo ideal de producción, aunque el manejo y tratamiento de datos es muy considerable y pesado de inicio.

Periodo Horario: datos de producción horaria desde las 8:00 h hasta las 17:00 h. Es decir, por cada variable de entrada en la red disponemos de 10 valores diarios. Se ha considerado dicho horario con objeto de disponer de una producción importante en todas las horas independientemente de la época del año. No tendría sentido por ejemplo considerar las 20:00 h puesto que lo lógico es que en el periodo estival la producción sea 0. El esfuerzo del proyecto va encaminado en optimizar la producción, esfuerzo muy importante que no sería acorde para la mejora de un número menor de Kw.

De dichos datos consideramos el 75% de la red para entrenamiento y el 25% para testeo.

Posteriormente los datos son tratados, validados y finalmente normalizados directamente en el software implementado para la obtención del modelo ideal de producción, que en nuestro caso particular el software utilizado ha sido R.

El periodo para la comparación debido al conocimiento de la existencia del fallo de estudio, ha sido Septiembre y Octubre del 2012. De ahí que el entrenamiento se haya realizado en fechas previas para que la red esté entrenada según el modelo más adaptado o próximo a la fecha de estudio. Lo ideal de la red es tenerla entrenada del modo más continuo posible, algo que con la implementación creada es muy sencillo de realizar.

Los datos seleccionados son en un comportamiento normal de la planta y por tanto en ausencia de fallos. Debido a que han existido fallos en el periodo considerado, se ha realizado un filtrado previo de todos los datos de estudio. Caso de existir un fallo se ha sustituido por un valor en condiciones normales considerando la media de producción entre los dos días anteriores y los dos días posteriores a dicha producción.

Para la obtención de los valores de las temperaturas se obtienen cuatro valores cada hora, considerando en el estudio la media horaria de dichos valores.

La escala para la temperatura son grados Kelvin. Se ha realizado el entrenamiento y comparación con grados centígrados obteniendo peores resultados. Al ser valores

mayores existe mayor diferencia y por tanto mayor sensibilidad detectada en los cambios.

1.5 Resultados.

El primero de los objetivos planteados ha sido el de la obtención del Modelo Ideal de Producción, el cual viene determinado tras el entrenamiento de la Red Neuronal por una topología óptima y unos valores de los pesos que unen las diferentes neuronas de las diferentes capas. A continuación exponemos los datos obtenidos con las técnicas empleadas así como la arquitectura óptima de la red seleccionada y un gráfico del entrenamiento de la red que denota la proximidad de los valores obtenidos con los valores deseados.

Técnica de Resolución: RNA

Red: Backpropagation

Algoritmo de Minimización del ECM: Cuasi_Newton con Penalización.

Software: R

Iteraciones para el Entrenamiento: 1000

Valores para el Entrenamiento: 75% del conjunto

Valores para el Testeo: 25%

ECM: 75.21266. (Error Cuadrático Medio)

R2: 0.905068 (Coeficiente de correlación o bondad del ajuste)

Coeficiente de Penalización: 0

Variables de Entrada: 4

Variables de Salida: 1

Número de Células de la Capa Oculta: 10

Periodo de Estudio: Junio 2011 – Julio 2012

Horario de Producción estudiado: desde las 8:00 hasta las 17:00

Figura 3. Arquitectura Seleccionada de la Red Óptima

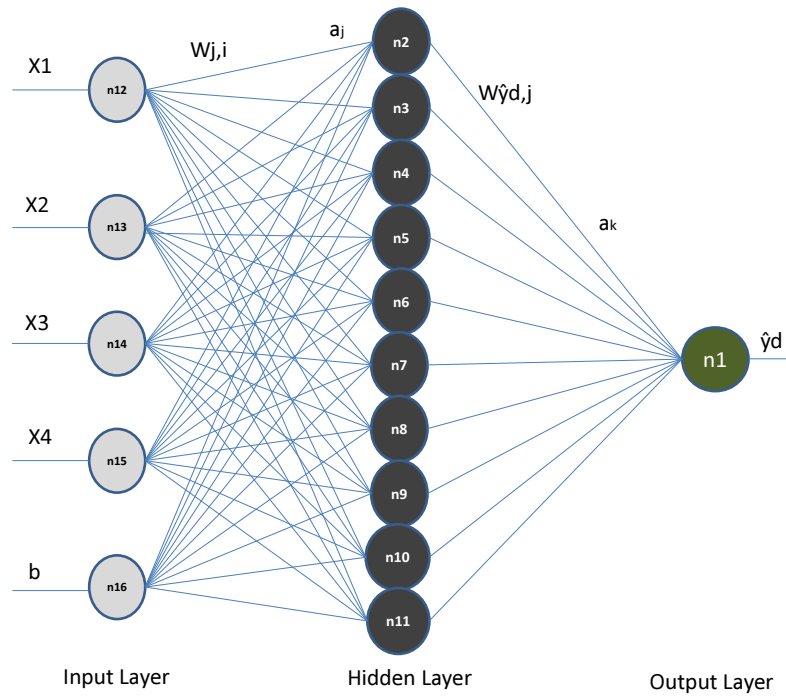




Figura 4. Nube de Puntos frente a la recta de valores reales del entrenamiento.



1.6 Conclusiones.

Una vez obtenido como resultado el modelo ideal de producción, éste es utilizado para obtener conclusiones más específicas. En este caso en particular nos hemos centrado en la Mejora de la Eficiencia Energética de la Instalación Fotovoltaica con la detección temprana de Fallos. Para ello comparamos la predicción obtenida con el modelo ideal de producción con la producción real, siendo el siguiente gráfico una comparativa de ello.

Figura 5. Comparación Predicción Modelo Ideal con Producción Real Diaria.



La mejora en la producción la obtenemos con la anticipación al fallo, mediante la definición de una condición de alarma. Dicha alarma es activada si la producción real horaria en una instalación tipo de 100 Kw es inferior al 40% a la predicción del Modelo Ideal de Producción manteniéndose esta condición de modo consecutivo durante 4 horas.

El fallo objeto de estudio que ha permitido la detección temprana de dicho error, ha sido el Fallo de Aislamiento estudiado sobre la instalación tipo seleccionada. Este fallo provocado por corrosiones de ciertos materiales a la intemperie en época de lluvia es la causa de degradaciones en la producción, durante al menos 48 horas previas, al fallo detectado por el Sistema de Monitorización, con las importantes pérdidas de producción que ello suponía.

La anticipación de un solo fallo de este tipo nos permite generar una media de 1400kw/h más, o lo que es lo mismo con ello ganamos 600 € de más al año en la producción. Extrapolando a una media real ocurrida de 3 fallos/año por cada una de las 61 instalaciones tipo de la Planta objeto de estudio, implica que el implantar este tipo de técnicas nos aportaría (contando sólo este modo de fallo) al año una ganancia de 256.200 Kw/h suponiendo un importe anual superior a los 110.000 €, o lo que es lo mismo un incremento en la producción de un 1.8%.

2. Referencias.

- Ashraf, I. & Chandra, A. (2004) Artificial neural network based models for forecasting electricity generation of grid connected solar PV power plant. *International journal of global energy issues*, 21, 119-130.
- Basheer, I. A. & Hajmeer, M. (2000) Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43, 3-31.
- Benghanem, M. & Mellit, A. (2010) Radial Basis Function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia. *Energy*, 35, 3751-3762.
- Campbell, J. & Jardine, A. *Maintenance Excellence: Optimising Equipment Life-cycle Decisions*, 2001. Marcel Dekker: New York, NY.
- Crespo Márquez, A. (2007) *The maintenance management framework: models and methods for complex systems maintenance*. Springer Verlag, London.
- Curry, B., Morgan, P. & Beynon, M. (2000) Neural networks and flexible approximations. *IMA Journal of Management Mathematics*, 11, 19-35.
- Hastie, T., Tibshirani, R., Friedman, J. (2001) *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Series: Springer Series in Statistics. XVI, 536 p. ISBN 978-0-387-21606-5.
- Hiyama, T. (1997) Neural network based estimation of maximum power generation from PV module using environmental information - Discussion. *Ieee Transactions on Energy Conversion*, 12, 247-247.
- Kalogirou, S. A. (2001) Artificial neural networks in renewable energy systems applications: a review. *Renewable & Sustainable Energy Reviews*, 5, 373-401.
- Kuo, C. (2011) Cost efficiency estimations and the equity returns for the US public solar energy firms in 1990–2008. *IMA Journal of Management Mathematics*, 22, 307-321.
- Lapedes, A. & Farber, R. (1987) Nonlinear signal processing using neural networks.
- Malcolm, B., Bruce, C. & Morgan, P. (1999) Neural networks and finite-order approximations. *IMA Journal of Management Mathematics*, 10, 225-244.
- Mellit, A., Benghanem, M., Arab, A. H. & Guessoum, A. (2005a) An adaptive artificial neural network model for sizing stand-alone photovoltaic systems: application for isolated sites in Algeria. *Renewable Energy*, 30, 1501-1524.
- Mellit, A., Benghanem, M., Arab, A. H., Guessoum, A. & IEEE (2003) Modelling of sizing the photovoltaic system parameters using artificial neural network.
- Mellit, A., Benghanem, M., Bendekhis, M. & IEEE (2005b) Artificial neural network model for prediction solar radiation data: Application for sizing, stand-alone photovoltaic power system. 2005 Ieee Power Engineering Society General Meeting, Vols, 1-3.
- Mellit, A., Benghanem, M., Hadj Arab, A., Guessoum, A. & IEEE (2004) An adaptive wavenet model for sizing of stand-alone photovoltaic systems.
- Mellit, A. & Kalogirou, S. A. (2008) Artificial intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*, 34, 574-632.
- Mellit, A. & Shaari, S. (2009) Recurrent neural network-based forecasting of the daily electricity generation of a Photovoltaic power system. *Ecological Vehicle and Renewable Energy (EVER)*, Monaco, March, 26-29.
- Moubray, J. (1997) *Reliability-centered maintenance*. Industrial Press Inc.
- Pham, H. & Wang, H. (1996) Imperfect maintenance. *European journal of operational research*, 94, 425-438.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986) Learning internal representations by error propagation. In Rumelhart, D. E., McClelland, J. L., and the PDP Research Group, editors, *Paralled Distributed Processing. Explorations in the Microstructure of Cognition*. Volume 1: Foundations, pages 318-362. The MIT Press, Cambridge, MA.
- Rausand, M. & Hoyland, A. (2004) *System reliability theory: models, statistical methods, and applications*, vol. 396. John Wiley & Sons.

- Rutkowski, Leszek (2008) *Computational Intelligence: Methods and Techniques*. Original Polish edition published by Polish Scientific Publishers. ISBN 978-3-540-76288-1
- Werbos, P. J. (1994) *The roots of backpropagation: from ordered derivatives to neural networks and political forecasting*, vol. 1. John Wiley & Sons.
- Wilson, R. L. (1986) Operations and support cost model for new product concept development. *Computers & Industrial Engineering*, 11, 128-131.
- Yacef, R., Benghanem, M. & Mellit, A. (2012) Prediction of daily global solar irradiation data using Bayesian neural network: A comparative study. *Renewable Energy*, 48, 146-154.
- Zhang, G. Q., Patuwo, B. E. & HU, M. Y. (1998) Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.