

# Diseño de redes neuronales inteligentes para la realización de pronósticos en microrredes eléctricas.

*Intelligent neural network design for forecasting loads in electric micro networks.*

---

Juan Pablo Fossati<sup>1</sup>

Recibido: 08/2018

Aceptado: 09/2019

---

**Resumen.** - Conocer de antemano los perfiles de demanda y de potencia generada por las fuentes renovables constituye un aspecto esencial para la optimización de la operación de las redes eléctricas. En el caso particular de las microrredes dicho aspecto cobra aún más importancia ya que en general un alto porcentaje de la energía generada proviene de fuentes renovables. A esto debe sumársele el hecho de que debido a un efecto de escala los parámetros a pronosticar están sometidos a una gran variabilidad. En este artículo se propone una metodología para el diseño de sistemas de pronósticos basados en redes neuronales artificiales (RNA) y algoritmos genéticos.

**Palabras Clave:** Redes neuronales artificiales, Pronósticos, Microrredes eléctricas, Algoritmos genéticos.

**Abstract.** - *Being able to predict power demand and output from renewable energy sources is an essential asset for the optimization of the performance of electric networks. In the particular case of microgrids the importance of that ability is enhanced even more so, since in general a great percentage of the energy generated comes from renewable sources. These parameters fluctuate substantially due to the scale in which they operate, so the need to predict their values acquires further significance. In this article we propose a methodology for the design of forecasting systems based on artificial neural networks (ANN).*

**Keywords:** *Artificial Neural Networks (ANN), Forecasting, Electric Microgrids, Genetic Algorithms.*

---

<sup>1</sup> Departamento de Ingeniería Eléctrica. Universidad de Montevideo. [jfossati@um.edu.uy](mailto:jfossati@um.edu.uy)

Memoria Investigaciones en Ingeniería, 2019. N°17(1). pp 1-13

<https://doi.org/10.36561/ING.17.2>

ISSN 2301-1092 • ISSN (en línea) 2301-1106

**1. Introducción.** - Las fuentes renovables juegan un papel cada vez más importante en la generación eléctrica. Uno de los puntos claves a la hora de optimizar la gestión de la energía generada por dichas fuentes es la elaboración de pronósticos. Por otro lado, en las dos últimas décadas las microrredes eléctricas se han presentado como un nuevo paradigma que busca desplazar al modelo tradicional de generación y consumo. En este artículo se propone una metodología para el diseño de sistemas de pronósticos basados en redes neuronales artificiales (RNA) y algoritmos genéticos. En la sección 2 del artículo se presentan algunos métodos empleados para la elaboración de pronósticos. En la sección 3 se propone una metodología de diseño de sistemas de pronósticos, en la sección 4 se analiza el desempeño de distintos sistemas de pronósticos generados por la metodología en cuestión y por último en la sección 5 se extraen las conclusiones.

**2. Métodos utilizados para la realización de pronósticos.** - A continuación, se describen algunas de las técnicas usualmente empleadas para la realización de pronósticos de demanda y generación de las fuentes renovables.

### 2.1. Métodos estadísticos:

**2.1.1. Análisis de regresión.** - El análisis de regresión es una de las técnicas más utilizadas para realizar pronósticos de demanda. Dicha técnica se emplea para modelar la relación entre la demanda y otros factores tales como las condiciones meteorológicas, el tipo de día, la clase de consumidores, etc. El modelo utilizado para representar la demanda  $P_D^t$  tiene la siguiente forma [1,2].

$$P_D^t = P_{De}^t + \sum_i \alpha_i \cdot \beta_i^t + \epsilon^t \quad (1)$$

donde el superíndice t hace referencia al tiempo,  $P_{De}^t$  es la demanda estándar,  $\beta_i^t$  la i-ésima variable independiente de la cual depende la variable a pronosticar (por ejemplo, condiciones meteorológicas),  $\alpha_i$  es un factor de ponderación de  $\beta_i^t$  y  $\epsilon^t$  es una componente aleatoria. Una gran parte de los trabajos relativos a regresiones lineales están enfocados en la determinación de las variables que influyen en el pronóstico de la demanda [3,4].

**2.1.2. Métodos basados en series temporales.** - Los métodos basados en series temporales asumen que los datos tienen una estructura interna como por ejemplo auto-correlación de los datos, tendencias, variaciones estacionales, etc. Los principales métodos existentes son el ARMA (*Autoregressive Moving Average*), el ARIMA (*Autoregressive Integrated Moving Average*), ARMAX (*Autoregressive Moving Average with Exogenous Variables*), y ARIMAX (*Autoregressive Integrated Moving Average with Exogenous Variables*) [2]. Los modelos ARMA son usados en general para procesos estacionarios mientras que los modelos ARIMA son usados para procesos no estacionarios.

Tanto el método ARMA como el ARIMA utilizan exclusivamente datos históricos de la variable a pronosticar mientras que el método ARIMAX permite la inclusión de otros parámetros [2]. En [5] se emplean distintos métodos basados en el modelo ARMA con el fin de predecir la velocidad y la dirección del viento a corto plazo. En [6] se utiliza un modelo ARMA para predecir la irradiación solar con el fin de gestionar adecuadamente la energía en una microrred.

**2.1.3. Métodos basados en *Soft computing*.** - La *soft computing* es una rama de la inteligencia artificial centrada en el diseño de sistemas inteligentes capaces de manejar adecuadamente información incierta, imprecisa y/o incompleta. El término *soft computing* engloba técnicas tales como las redes neuronales artificiales (RNA), la lógica difusa, los algoritmos evolutivos o los algoritmos basados en inteligencia de enjambre [7]. Dichas técnicas permiten modelar sistemas complejos que resultarían muy difíciles de abordar por métodos analíticos convencionales.

Otra ventaja de estos métodos es el hecho de que pueden “aprender” en ambientes caracterizados por la imprecisión y la incertidumbre. Estas características hacen que la *soft computing* sea ampliamente usada para la realización de predicciones. A continuación, se destacan algunos aspectos de las redes neuronales, ya que esta ha sido la técnica empleada en el desarrollo de los sistemas de pronósticos.

Uno de los principales desafíos que plantean las redes neuronales utilizadas para la realización de pronósticos es que no existe ningún método preconcebido para el diseño de las mismas. Por este motivo, ante un problema específico, no resulta sencillo establecer el tipo de red a usar ni los parámetros que la definen (número de capas, número de neuronas en cada capa, parámetros relativos al entrenamiento de la red, etc.). Debido a esto, una gran parte de los artículos relacionados al uso de redes neuronales en el ámbito de los pronósticos se centran en el diseño de las mismas.

En [8] por ejemplo se utiliza una red neuronal tipo *feedforward* para predecir la demanda tomándose como entradas datos históricos de consumo eléctrico, el día de la semana y la temperatura. En [9] se emplea una red neuronal del mismo tipo que la utilizada en [8] pero incluyendo el precio de la electricidad como una de las variables de entrada. En [10] se diseñan y comparan tres tipos de redes neuronales utilizadas para predecir la velocidad del viento. El entrenamiento de dichas redes se lleva a cabo por medio de un algoritmo de optimización por enjambre de partículas. En [11] se utiliza una red neuronal para predecir la irradiación en las próximas 24 horas. Como datos de entrada la red se utiliza la irradiación y la temperatura del día previo al pronóstico.

**2.2. Modelos numéricos de predicción meteorológica.** - Los modelos de predicción meteorológica o modelos NWP (*Numerical Weather Prediction*), son usados para predecir el estado de la atmósfera con un horizonte temporal máximo que puede variar entre 15 y 240 horas. En este tipo de métodos la atmósfera se modela por un conjunto de ecuaciones diferenciales que describen las leyes físicas que regulan su comportamiento. El primer modelo NWP fue presentado a principios de siglo por el científico noruego Vilhelm Bjerknes [12]. Desde entonces se han realizado importantes avances en este tipo de métodos principalmente debido al hecho de que los adelantos en las ciencias de la informática han permitido reducir los tiempos de resolución de las ecuaciones diferenciales que rigen el comportamiento de la atmósfera.

Existen en la actualidad diversas entidades que utilizan modelos NWP para realizar pronósticos a nivel global. Dos de los más destacados centros son la NOAA (*National Oceanic and Atmospheric Administration*) y el ECMWF (*European Centre for Medium-Range Weather Forecasts*). Si bien los modelos globales abarcan la totalidad de la tierra, estos tienen una baja resolución espacial (16-50 km). Para mejorar este aspecto se emplean modelos regionales que son llevados a cabo por agencias nacionales o compañías privadas llegando a alcanzar resoluciones espaciales de 1 km.

En el caso de los modelos globales los datos de entrada son extraídos de redes mundiales de observación y medida. Dichos datos incluyen la temperatura, el viento, la humedad y la presión atmosférica sobre la superficie terrestre. Otras variables tales como la cubierta de nieve o la temperatura superficial de los océanos deben incluirse para establecer las condiciones de frontera del problema. Por otra parte, los modelos regionales utilizan los datos proporcionados por los modelos globales, así como datos meteorológicos propios. Los datos de salida de los modelos NWP incluyen variables tales como la temperatura, la velocidad del viento, el nivel de irradiación o la presión. La resolución temporal para este tipo de pronósticos es de entre 3 y 6 horas para los modelos globales y de una hora para los modelos regionales.

**3. Metodología de diseño propuesta.** - En esta sección se describe la metodología empleada para diseñar las redes neuronales de los sistemas de pronóstico de demanda y de generación de las fuentes renovables. Dicha metodología emplea algoritmos genéticos con el fin de determinar las características óptimas de las RNA.

Debido a que hay demasiados parámetros a definir, no resultaría ni eficiente ni efectivo hacer evolucionar dichas variables simultáneamente. Por este motivo, el algoritmo utilizado para el diseño de las RNA se ha dividido en tres niveles. En el primer nivel se determinan las entradas de la red neuronal. En el segundo nivel se define la arquitectura mientras que en el tercer nivel se define el entrenamiento (tasas de aprendizaje y constante de momento) y los pesos de las interconexiones. A continuación, en la Figura I, se describen los distintos niveles mencionados anteriormente.

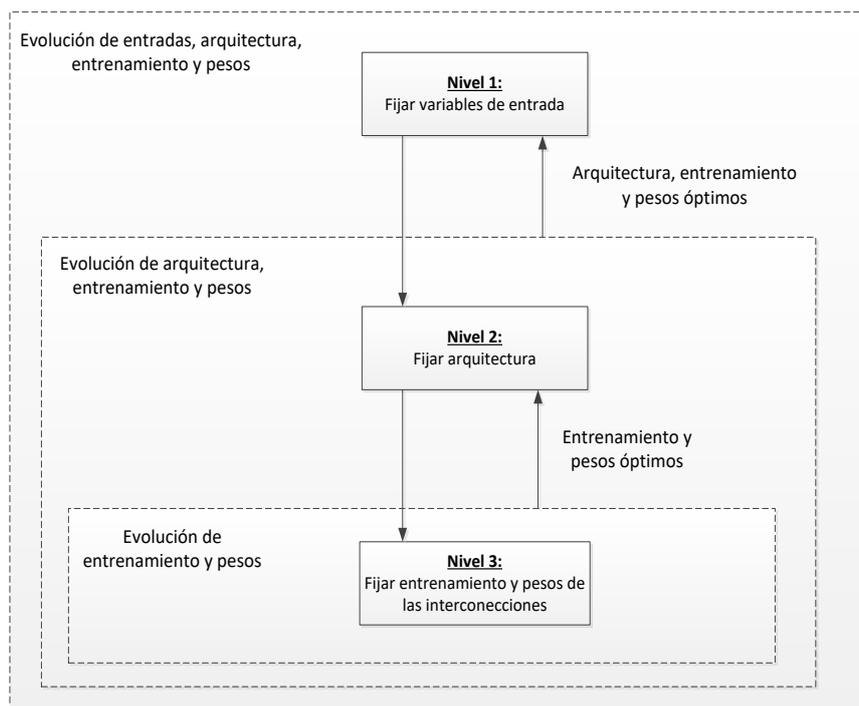


Figura I.- Esquema de la metodología utilizada para determinar el diseño óptimo de las redes neuronales.

**3.1. Primer nivel.** - Tal y como se mencionó en la sección anterior en el primer nivel se determina el conjunto de variables que servirán como entradas de la red neuronal. Dichas entradas no se modifican cuando se ejecutan los algoritmos de los niveles 2 y 3. Tanto para la demanda como para la potencia generada por las fuentes renovables, el conjunto de posibles entradas se ha acotado. Por este motivo, en este nivel no se utiliza un algoritmo genético para seleccionar el mejor conjunto de entradas, sino que se analizan uno a uno.

Las entradas pueden clasificarse en dos categorías. En la primera categoría se sitúan aquellas variables que aportan datos sobre las últimas 24 horas. Ejemplo de esto podrían ser la velocidad del viento en las últimas 24 horas, el consumo eléctrico el día previo o la temperatura promedio durante las últimas 24 horas etc. El segundo tipo de variables de entrada aportan datos sobre el periodo de tiempo que se quiere pronosticar, es decir sobre las siguientes 24 horas. Ejemplo de este tipo de parámetros podrían ser el día del año, el tipo de día (festivo, laborable), la hora o un pronóstico realizado por medio de un modelo numérico. Para poder definir las entradas es preciso conocer el tipo de salida requerida. A continuación, se detallan las distintas variables a pronosticar.

- Potencia generada por los paneles fotovoltaicos durante las próximas 24 horas. (24 valores en intervalos de una hora).
- Potencia generada por los aerogeneradores durante las próximas 24 horas. (24 valores en intervalos de una hora).
- Demanda eléctrica durante las próximas 24 horas. (24 valores en intervalos de una hora).

Habiendo ya definido las salidas, a continuación, se detallan el conjunto de entradas utilizadas para realizar los pronósticos.

**3.1.2. Variables de entrada utilizadas para el pronóstico de la potencia generada por los paneles fotovoltaicos.** - En esta sección se especifican las variables de entrada propuestas para el pronóstico de la potencia generada por los paneles fotovoltaicos.

3.1.2.1. Una de las variables de entrada más importantes empleadas en el pronóstico de la potencia generada por los paneles fotovoltaicos es la radiación extraterrestre. Para realizar las predicciones se emplean 17 valores de radiación extraterrestre correspondientes al día que se desea pronosticar y al período que va de las 5:00 horas a las 22:00 horas.

3.1.2.2. Irradiación promedio durante el día previo en plano horizontal. Se considera el período de tiempo que va de las 5:00 horas a las 22:00 horas ( $W/m^2$ ).

$$\bar{G}_p = \frac{1}{17} \sum_{t=5}^{21} G^t \quad (2)$$

donde  $G^t$  es la irradiación incidente sobre la superficie terrestre en la  $t$ -ésima hora del día.

3.1.2.3. Irradiación sobre la superficie terrestre ( $W/m^2$ ) durante el día previo. Se toman 17 valores correspondientes al periodo que va de las 5:00 horas a las 22:00 horas.

$$\bar{G} = [G^5, G^6, \dots, G^{21}] \quad (3)$$

3.1.2.4. Mes del año. Dado que esta variable es periódica, en lugar de ingresar un solo valor se utilizan los valores sinusoidales  $m_1$  y  $m_2$  tal y como se muestra en las ecuaciones (4) y (5). Esto se debe a que las variables cíclicas son mejor entendidas por las redes neuronales si se las presenta de esa manera [13].

$$m_1 = \text{sen}(2 \cdot \pi \cdot \text{mes}/12) \quad (4)$$

$$m_2 = \cos(2. \pi. mes/12) \quad (5)$$

donde *mes* es un número natural del 1 al 12 indicando el mes del año.

3.1.2.5. Vector de datos  $\overline{Tp}$  que contiene cuatro valores de temperatura asociados a las últimas 24 horas.

$$\overline{Tp} = [Tp_1, Tp_2, Tp_3, Tp_4] \quad (2.1.1)$$

$Tp_1$	Temperatura promedio de 00:00 horas a 06:00 horas
$Tp_2$	Temperatura promedio de 06:00 horas a 12:00 horas
$Tp_3$	Temperatura promedio de 12:00 horas a 18:00 horas
$Tp_4$	Temperatura promedio de 18:00 horas a 00:00 horas

3.1.2.6. Vector de datos  $\overline{Pa}$  con cuatro valores de presión atmosférica de últimas 24 horas.

$$\overline{Pa} = [Pa_1, Pa_2, Pa_3, Pa_4] \quad (7)$$

$Pa_1$	Presión atmosférica promedio de 00:00 horas a 06:00 horas
$Pa_2$	Presión atmosférica promedio de 06:00 horas a 12:00 horas
$Pa_3$	Presión atmosférica promedio de 12:00 horas a 18:00 horas
$Pa_4$	Presión atmosférica promedio de 18:00 horas a 00:00 horas

3.1.2.7. Vector de datos  $\overline{Hr}$  que contiene cuatro valores de humedad relativa asociados a las últimas 24 horas

$$\overline{Hr} = [Hr_1, Hr_2, Hr_3, Hr_4] \quad (8)$$

$Hr_1$	Humedad relativa promedio de 00:00 horas a 06:00 horas
$Hr_2$	Humedad relativa promedio de 06:00 horas a 12:00 horas
$Hr_3$	Humedad relativa promedio de 12:00 horas a 18:00 horas
$Hr_4$	Humedad relativa promedio de 18:00 horas a 00:00 horas

3.1.2.8. Es común que como variable de entrada se incluyan pronósticos provenientes de alguna agencia meteorológica [14]. A diferencia de las entradas vistas hasta el momento este tipo de parámetros provienen de modelos físicos por lo que aportan información muy valiosa. En el caso del pronóstico de la energía generada por los paneles fotovoltaicos, es de interés conocer el grado de nubosidad que presentará el día a pronosticar. Esta información se detalla por lo general de forma porcentual. Se emplean las siguientes expresiones para especificar el porcentaje del cielo que estará cubierto por nubes.

- Despejado o poco nuboso: 0-12.5%
- Parcialmente nuboso: 12.5-50%
- Nuboso: 50-62.5%
- Muy nuboso: 62.5-87.5%
- Cubierto: 87.5-100%

3.1.2.9. Para la determinación de la potencia generada por los paneles fotovoltaicos se ha incluido como entrada un vector  $\overline{Nb}$  que contiene cuatro valores que indican el nivel de nubosidad del día que se desea pronosticar (ecuación (9)). Dichos valores varían entre 1 y 5 dependiendo del porcentaje de cielo cubierto. (1-despejado o poco nuboso, 2-parcialmente nuboso, 3-nuboso, 4-muy nuboso, 5-cubierto).

(9)

$$\overline{Nb} = [Nb_1, Nb_2, Nb_3, Nb_4]$$

$Nb_1$	Nubosidad promedio de 05:00 horas a 10:00 horas (valor entre 1 y 5)
$Nb_2$	Nubosidad promedio de 10:00 horas a 14:00 horas (valor entre 1 y 5)
$Nb_3$	Nubosidad promedio de 14:00 horas a 18:00 horas (valor entre 1 y 5)
$Nb_4$	Nubosidad promedio de 18:00 horas a 22:00 horas (valor entre 1 y 5)

3.1.2.10. Si bien los datos aportados por agencias meteorológicas brindan información muy valiosa, estos son obtenidos para regiones bastante amplias. Por este motivo es importante incluir dentro de las entradas variables relativas al punto exacto en el que se desea hacer la predicción.

- Pronóstico de temperatura para las siguientes 24 horas (se utiliza el promedio diario).
- Pronóstico de presión atmosférica para las siguientes 24 horas (se utiliza el promedio diario).
- Pronóstico de humedad relativa para las siguientes 24 horas (se utiliza el promedio diario).

**3.1.3. Variables de entrada utilizadas para el pronóstico de la potencia generada por aerogeneradores.** - En esta sección se especifican las variables de entrada propuestas para el pronóstico de la potencia generada por los aerogeneradores

3.1.3.1. Velocidad del viento promedio durante las últimas 24 horas.

$$\bar{v}_p = \frac{1}{24} \sum_{t=1}^{24} v^t \quad (10)$$

donde  $v^t$  es la velocidad del viento en la  $t$ -ésima hora del día.

3.1.3.2. Velocidad del viento durante las últimas 24 horas. La entrada es un vector que contiene 24 valores de velocidad (uno por cada hora del día).

$$\bar{V} = [v^1, v^2, \dots, v^{24}] \quad (11)$$

3.1.3.3. Mes del año (ecuaciones (4) y (5)).

3.1.3.4. Vector de datos  $\overline{Tp}$  que contiene cuatro valores de temperatura asociados a las últimas 24 horas (ecuación (2.1.1)).

3.1.3.5. Vector de datos  $\overline{Pa}$  que contiene cuatro valores de presión atmosférica asociados a las últimas 24 horas (ecuación (7)).

3.1.3.6. Vector de datos  $\overline{Hr}$  que contiene cuatro valores de humedad relativa asociados a las últimas 24 horas (ecuación (8)).

3.1.3.7. Al igual que con el pronóstico de la potencia generada por los paneles fotovoltaicos, para el caso los aerogeneradores también se incluyen variables obtenidas a partir de un modelo físico. Las agencias meteorológicas brindan información acerca de la velocidad del viento ya sea indicando el valor en km/h o por medio de los siguientes términos [15].

- Calmo: 0-5 km/h
- Flojo: 15-20 km/h
- Moderado: 20-40 km/h
- Fuerte: 40-70 km/h

- Muy fuerte: 70-120 km/h
- Huracanado: superior a 120 km/h

3.1.3.8. Para la determinación de la potencia generada por los aerogeneradores se ha incluido como entrada un vector  $\vec{V}_{pr}$  que contiene cuatro valores asociados a la velocidad del viento del día que se desea pronosticar (ecuación (12)). Dichos valores varían entre 1 y 6 de acuerdo al siguiente criterio: 1-calmo, 2-flojo, 3-moderado, 4-fuerte, 5-muy fuerte, 6-huracanado.

$$\vec{V}_{pr} = [V_1, V_2, V_3, V_4] \quad (12)$$

$V_1$  Velocidad del viento promedio de 00:00 horas a 06:00 horas (valor entre 1 y 6)

$V_2$  Velocidad del viento promedio de 06:00 horas a 12:00 horas (valor entre 1 y 6)

$V_3$  Velocidad del viento promedio de 12:00 horas a 18:00 horas (valor entre 1 y 6)

$V_4$  Velocidad del viento promedio de 18:00 horas a 00:00 horas (valor entre 1 y 6)

3.1.3.9. Pronóstico de temperatura para las siguientes 24 horas (se utiliza el promedio diario).

3.1.3.10. Pronóstico de presión atmosférica para las siguientes 24 horas (se utiliza el promedio diario).

3.1.3.11. Pronóstico de humedad relativa para las siguientes 24 horas (se utiliza el promedio diario).

**3.1.4. Variables de entrada utilizadas para el pronóstico de la demanda eléctrica.** - En esta sección se especifican las variables de entrada propuestas para el pronóstico de la demanda eléctrica. Luego se definen los conjuntos de entradas a ser evaluados durante el proceso de diseño. Cabe señalar que, en comparación con la potencia generada por las fuentes renovables, la demanda eléctrica es un fenómeno mucho más cíclico y depende de menos variables.

3.1.4.1. Mes del año (ecuaciones (4) y (5)).

3.1.4.2. Día de la semana que se representa mediante dos valores sinusoidales.

$$d_1 = \text{seno}(2 \cdot \pi \cdot \text{dia}/7) \quad (13)$$

$$d_2 = \text{cos}(2 \cdot \pi \cdot \text{dia}/7) \quad (14)$$

donde *dia* es un número natural del 1 al 7 utilizado para designar el día de la semana.

3.1.4.3. Demanda eléctrica durante las últimas 24 horas. Los datos se ingresan en forma de un vector  $\vec{P}_D$  que contiene 24 valores de potencia (un valor por cada hora del día).

$$\vec{P}_D = [P_D^1, P_D^2, \dots, P_D^{24}] \quad (15)$$

3.1.4.4. Tipo de día según si es o no laborable (“0” para laborable, “1” para no laborable).

3.1.4.5. Pronóstico de temperatura para las siguientes 24 horas (se utiliza el promedio diario).

**3.1.5. Conjunto de entradas seleccionadas para el primer nivel.** - Con el fin de determinar los parámetros de entrada óptimos para cada variable a pronosticar, las entradas se han agrupado en una serie de conjuntos que se detallan a continuación. Para identificar a las entradas se han utilizado los números asignados en las secciones anteriores.

#### Potencia generada por los paneles solares

- Conjunto de variables de entrada 1: todas las variables (del 1 al 11).
- Conjunto de variables de entrada 2: 1, 3, 5, 6, 7, 8, 9, 10, 11.
- Conjunto de variables de entrada 3: 1, 2, 4, 5, 8, 9.

Memoria Investigaciones en Ingeniería, 2019. N°17(1). pp 1-13

<https://doi.org/10.36561/ING.17.2>

ISSN 2301-1092 • ISSN (en línea) 2301-1106

- Conjunto de variables de entrada 4: 1, 2, 4, 6, 8, 10.
- Conjunto de variables de entrada 5: 1, 2, 4, 7, 8, 11.

#### Potencia generada por los aerogeneradores

- Conjunto de variables de entrada 1: 2, 7.
- Conjunto de variables de entrada 2: 1, 2, 3, 4, 7, 8.
- Conjunto de variables de entrada 3: 1, 2, 3, 5, 7, 9.
- Conjunto de variables de entrada 4: 2, 3, 4, 5, 6, 7, 8, 9, 10.
- Conjunto de variables de entrada 5: 1, 2, 3, 6, 7, 10.

#### Demanda eléctrica

- Conjunto de variables de entrada 1: 1, 2, 3, 4, 5.
- Conjunto de variables de entrada 2: 1, 2, 3.
- Conjunto de variables de entrada 3: 3, 4.

**3.2. Segundo nivel.** - Dado que en el primer nivel se establecieron las variables empleadas como entradas, el número de neuronas en la primera capa queda automáticamente definido. En lo que respecta a la arquitectura resta entonces fijar el número de capas intermedias (1 o 2), el número de neuronas por capa (para las capas intermedias) y las funciones de transferencia. Debido a que usualmente se utiliza un mismo tipo de función de transferencia para una misma capa, este ha sido el modelo adoptado.

En el caso de las redes neuronales aplicar el operador cruce puede generar descendientes que guarden muy poca relación con sus progenitores en lo que respecta al desempeño. Por este motivo en el algoritmo empleado para el diseño de la arquitectura, y al igual que en [16], se emplean únicamente operadores mutación. Como puede verse en la Figura II, en cada cromosoma se representan los números de neuronas en la primera capa oculta, el número de neuronas en la segunda capa oculta y las funciones de transferencia utilizadas en las distintas capas.

Número de neuronas en la primera capa oculta (N1)	Número de neuronas en la segunda capa oculta (N2)	Tipo de función de transferencia utilizada en la capa de entrada	Tipo de función de transferencia utilizada en la primera capa oculta	Tipo de función de transferencia utilizada en la segunda capa oculta	Tipo de función de transferencia utilizada en la capa de salida
---	---	--	--	--	---

*Figura II. Codificación de la arquitectura de la red neuronal.*

**3.3. Tercer nivel.** - En el tercer nivel se entrenan y evalúan las distintas arquitecturas provenientes del nivel secundario. Como se dijo anteriormente los algoritmos basados en el método del gradiente son buenos para encontrar óptimos siempre y cuando se parta de una solución adecuada. De forma inversa, los algoritmos genéticos son buenos buscando soluciones en espacios de búsqueda amplios y con múltiples óptimos locales, pero no son tan eficientes una vez que el espacio de búsqueda ha sido restringido. Por este motivo se ha optado por realizar el entrenamiento por medio de un algoritmo híbrido; éste combina un algoritmo genético con el algoritmo *backpropagation* con momento. La idea es aplicar en primer lugar un algoritmo genético con el fin de determinar los pesos de las interconexiones iniciales que serán utilizados por el algoritmo *backpropagation* con momento. De esta forma se pretende evitar que el algoritmo *backpropagation* con momento converja prematuramente a un óptimo local.

Otro punto a considerar es la determinación de la tasa de aprendizaje  $\gamma$  y la constante de momento  $\tau$ . Tal y como se mencionó anteriormente, encontrar unos valores adecuados de estas dos variables es fundamental para evitar que el algoritmo oscile o converja prematuramente.

**4. Resultados.** - En esta sección se presentan los sistemas de pronósticos desarrollados para la previsión de la demanda eléctrica y la potencia generada por los paneles solares y aerogeneradores. Para cada uno de los sistemas se detallan las principales características de la red neuronal y se evalúa la performance de la misma en base al error medio absoluto porcentual (EMAP). Para evaluar el desempeño de las redes neuronales se emplearon un año de datos meteorológicos de la agencia vasca de meteorología y de consumo eléctrico de la ciudad de Pamplona.

#### 4.1. RNA para predecir la generación solar

**4.1.2. Características.** - A continuación, se describe la red neuronal obtenida tras la aplicación de la metodología propuesta. La red neuronal tiene 53 neuronas en la capa de entrada y cuenta con una sola capa intermedia de 42 neuronas. En las capas de entrada y de salida se emplean funciones sigmoideas, mientras que en la capa intermedia se utilizan tangentes hiperbólicas. En lo que respecta al entrenamiento, se han utilizado datos históricos relativos a los últimos 5 años, los cuales han sido extraídos de la agencia vasca de meteorología [17]. Por último, para la arquitectura en cuestión, se ha determinado que la tasa de aprendizaje y la constante de momento óptima son las siguientes:  $\tau = 0.44$  y  $\gamma = 0.082$ .

**4.1.3. Desempeño.** - La figura III muestra el desempeño de la red neuronal en función del tipo de día, es decir el nivel de nubosidad.

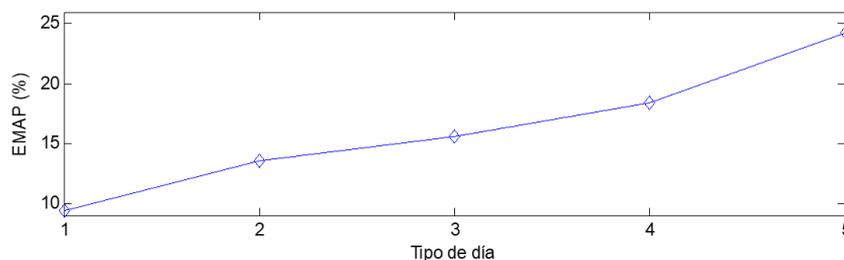


Figura III. Desempeño en función del nivel de nubosidad

## 4.2. RNA para predecir generación eólica.

**4.2.1. Características.** - A continuación, se describe la red neuronal obtenida tras la aplicación de la metodología propuesta. La capa de entrada tiene por lo tanto un total de 45 neuronas. La red neuronal cuenta a su vez con dos capas intermedias siendo la primera de 23 neuronas y la segunda de 18. En la capa de entrada se emplean funciones de transferencia lineales, mientras que en las restantes capas se emplean funciones sigmoideas. En lo que respecta al entrenamiento, se han utilizado datos históricos relativos a los últimos 5 años los cuales han sido extraídos de la agencia vasca de meteorología [15]. Por último, para la arquitectura en cuestión se ha determinado que la tasa de aprendizaje y la constante de momento óptima son las siguientes:  $\gamma = 0.023$  y  $\tau = 0.86$ .

**4.2.2. Desempeño.** - La figura IV muestra el desempeño de la red neuronal en función del tipo de día, es decir el nivel de viento.

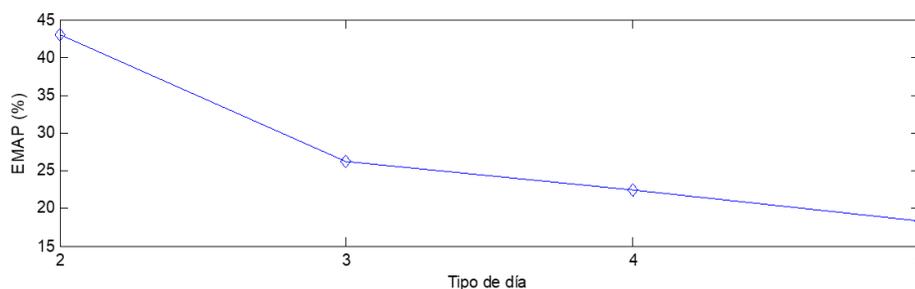


Figura IV: Desempeño en función del nivel de viento

## 4.3. RNA para predecir la demanda eléctrica.

**4.3.1. Características.** - A continuación, se describe la red neuronal obtenida tras la aplicación de la metodología propuesta. La red neuronal posee una sola capa intermedia la cual consta de 21 neuronas. Tanto la capa intermedia como la capa de salida emplean funciones sigmoideas, mientras que la capa de entrada utiliza funciones lineales. Se ha determinado que la tasa de aprendizaje y la constante de momento óptimas son:  $\gamma = 0.12$  y  $\tau = 0.23$

**4.3.2. Desempeño.** - La figura V muestra el desempeño de la red neuronal en función del tipo de día. Se emplean los números 1, 2 y 3 para designar respectivamente los días de semana, los sábados y los domingos.

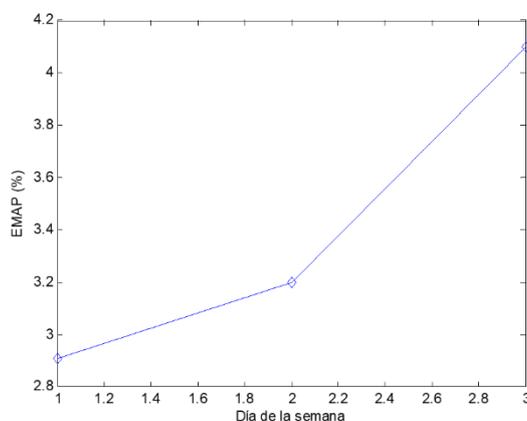


Figura V: Desempeño en función de los días de la semana

**5. Conclusiones.** - En el presente artículo se verificó la eficacia de las redes neuronales en lo que respecta la realización de pronósticos. El mayor problema al que se debe hacer frente al crear una red neuronal para realizar predicciones es que no existe ningún método preconcebido para dicho fin. La metodología propuesta, así como los algoritmos genéticos han demostrado ser una herramienta muy útil a la hora de optimizar el diseño de las RNAs.

## 6. Referencias

- [1] A. K. Singh, I. Ibraheem, S. Khatoun, M. Muazzam and D. Chaturvedi, "Load forecasting techniques and methodologies: A review," in *Power, Control and Embedded Systems (ICPCES), 2012 2nd International Conference on*, 2012, pp. 1-10.
- [2] A. K. Singh, S. K. Ibraheem and M. Muazzam, "An Overview of Electricity Demand Forecasting Techniques," *Network and Complex Systems*, vol. 3, pp. 38-48, 2013.
- [3] S. Ruzic, A. Vuckovic and N. Nikolic, "Weather sensitive method for short term load forecasting in electric power utility of Serbia," *Power Systems, IEEE Transactions on*, vol. 18, pp. 1581-1586, 2003.
- [4] R. F. Engle, C. Mustafa and J. Rice, "Modelling peak electricity demand," *J. Forecast.*, vol. 11, pp. 241-251, 1992.
- [5] E. Erdem and J. Shi, "ARMA based approaches for forecasting the tuple of wind speed and direction," *Appl. Energy*, vol. 88, pp. 1405-1414, 2011.
- [6] R. Huang, T. Huang, R. Gadh and N. Li, "Solar generation prediction using the ARMA model in a laboratory-level micro-grid," in *Smart Grid Communications (SmartGridComm), 2012 IEEE Third International Conference on*, 2012, pp. 528-533.
- [7] L. Magdalena, "What is soft computing? revisiting possible answers," *International Journal of Computational Intelligence Systems*, vol. 3, pp. 148-159, 2010.
- [8] A. Bakirtzis, V. Petridis, S. Kiartzis, M. Alexiadis and A. Maissis, "A neural network short term load forecasting model for the Greek power system," *Power Systems, IEEE Transactions on*, vol. 11, pp. 858-863, 1996.
- [9] H. Chen, C. A. Canizares and A. Singh, "ANN-based short-term load forecasting in electricity markets," in *Power Engineering Society Winter Meeting, 2001. IEEE*, 2001, pp. 411-415.

Memoria Investigaciones en Ingeniería, 2019. N°17(1). pp 1-13

<https://doi.org/10.36561/ING.17.2>

ISSN 2301-1092 • ISSN (en línea) 2301-1106

- [10] R. L. Welch, S. M. Ruffing and G. K. Venayagamoorthy, "Comparison of feedforward and feedback neural network architectures for short term wind speed prediction," in *Neural Networks, 2009. IJCNN 2009. International Joint Conference on*, 2009, pp. 3335-3340.
- [11] A. Mellit and A. M. Pavan, "A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy," *Solar Energy*, vol. 84, pp. 807-821, 2010.
- [12] P. Lynch, "The origins of computer weather prediction and climate modeling," *Journal of Computational Physics*, vol. 227, pp. 3431-3444, 2008.
- [13] L. Hernandez, C. Baladrón, J. M. Aguiar, B. Carro, A. J. Sanchez-Esguevillas and J. Lloret, "Short-term load forecasting for microgrids based on artificial neural networks," *Energies*, vol. 6, pp. 1385-1408, 2013.
- [14] C. Chen, S. Duan, T. Cai, B. Liu and G. Hu, "Smart energy management system for optimal microgrid economic operation," *Renewable Power Generation, IET*, vol. 5, pp. 258-267, 2011.
- [15] (16 de noviembre, 2014). *Agencia vasca de meteorología (manual de estilo)*. DOI: [http://www.euskalmet.euskadi.net/s075853x/es/contenidos/informacion/manual\\_estilo/es\\_9900/es\\_nubosidad.html](http://www.euskalmet.euskadi.net/s075853x/es/contenidos/informacion/manual_estilo/es_9900/es_nubosidad.html).
- [16] F. Heimes, G. Zalesski, W. Land Jr and M. Oshima, "Traditional and evolved dynamic neural networks for aircraft simulation," in *Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference on*, 1997, pp. 1995-2000.