

Predicción a Corto Plazo de la Velocidad del Viento en Parques Eólicos Mediante Redes Evolutivas de Unidades Producto

C. Hervás-Martínez

AYRNA research group

Dpto. Informática y Análisis Numérico

Universidad de Córdoba

chervas@uco.es

P. A. Gutiérrez

AYRNA research group

Dpto. Informática y Análisis Numérico

Universidad de Córdoba

pagutierrez@uco.es

S. Salcedo-Sanz

GHEODE research group

Dpto. de Teoría de la Señal

Universidad de Alcalá

sancho.salcedo@uah.es

E. Ortiz-García

GHEODE research group

Dpto. de Teoría de la Señal

Universidad de Alcalá

emilio.ortizg@uah.es

A. Portilla-Figueras

GHEODE research group

Dpto. de Teoría de la Señal

Universidad de Alcalá

antonio.portilla@uah.es

L. Prieto

Dpto. de Recurso Energético

Iberdrola Renovables

lprietog@iberdrola.es

Resumen

La combinación de modelos físicos y estadísticos en la predicción de la velocidad del viento en parques eólicos ha sido frecuentemente utilizada en los últimos años, dando lugar a sistemas robustos, y más precisos que los físicos o estadísticos por separado. Recientemente, diversos tipos de redes neuronales han sido empleadas en estos modelos híbridos físico-estadísticos, con buenos resultados. En este trabajo presentamos la evaluación de una red evolutiva de unidades producto (EPUNN) en uno de estos sistemas de predicción de viento en un parque eólico. Los resultados muestran la validez de este tipo de redes para su integración en este tipo de sistemas de predicción, y las posibilidades que brindan, tales como la interpretación de los resultados a partir de las relaciones no lineales entre las variables predictivas del modelo. Los resultados ofrecidos en este artículo han sido probados sobre datos reales en un parque eólico de España.

1. Introducción

La energía renovable en Europa está considerada actualmente como una línea priorita-

ria de actuación, con el objetivo de obtener un 20% de la electricidad total consumida a partir de fuentes renovables en 2020. Es esperable que la mayor parte de esta energía limpia provenga principalmente de fuentes eólicas, ya que hoy en día más del 13% de la electricidad consumida en España proviene de este tipo de energía. Es bien sabido que uno de los principales problemas de la integración de las energías renovables, fundamentalmente energías eólicas y fotovoltaicas, en la red, son los problemas asociados a la dificultad de predecir la producción de potencia de este tipo de sistemas. En el caso del viento, la variabilidad en la producción viene dada, evidentemente, por la variación de los periodos de velocidad del viento, prácticamente imposibles de predecir con precisión, que hacen que sea realmente muy difícil una gran integración en la red de este tipo de energías [1, 2, 3, 4, 5].

Aún así, el problema de la predicción en parques eólicos es un problema clave para las compañías gestoras de parques eólicos, ya que están obligadas por ley a efectuar dichas predicciones para evitar problemas de transporte de energía, siendo penalizadas si las predicciones se apartan considerablemente de la realidad. Hoy en día, las empresas utilizan moder-

nas técnicas de predicción basadas en sistemas híbridos que combinan modelos físicos y estadísticos. Los modelos físicos pueden ser globales, de mesoescala, o incluso locales, teniendo en cuenta las características específicas del parque eólico. Los modelos estadísticos suelen estar incluidos en los modelos de predicción conjuntamente con estos modelos físicos. Generalmente, se considera que los modelos estadísticos consiguen mejores resultados en la parte final del proceso de predicción.

Por otra parte, la predicción de potencia generada en un parque eólico puede tratarse desde dos puntos de vista: bien se puede estimar directamente la producción de un parque completo, o bien puede estimarse el viento en cada aerogenerador, para posteriormente, a partir de la curva de potencia, obtener su producción, y de forma inmediata la del parque. Esta última forma de trabajar es más efectiva, ya que permite evaluar la producción del parque en condiciones de trabajo específicas, por ejemplo si se requiere la parada de ciertos aerogeneradores, etc. En este sentido, ha habido diversos trabajos previos centrados en el diseño de modelos predictivos. Algunos de ellos se han basado exclusivamente en datos previos [6, 7], usualmente este tipo de estudios son útiles para predicciones a largo plazo. En estimaciones a corto plazo, la dinámica atmosférica juega un papel fundamental, y entonces es esencial la inclusión de modelos de tipo local o mesoescala, [8, 9]. En predicción a corto plazo han aparecido estudios que mezclan modelos físicos con modelos estadísticos modernos, tales como redes neuronales, [3, 10], máquinas de vectores soporte [11], modelos autoregresivos y de medias móviles ARMA [12], filtros de Kalman [4], etc.

En este artículo se propone un modelo de predicción del viento a partir de una predicción que mezcla modelos físicos y estadísticos. La novedad viene en que en la parte estadística probamos un nuevo tipo de red neuronal, una red de unidades producto (PUNN), con entrenamiento mediante algoritmos evolutivos. En el artículo describiremos el nuevo modelo de predicción que se genera con esta nueva red, analizando sus principales caracte-

rísticas y viendo su aplicación y rendimiento en la predicción del viento en un parque eólico en España.

El resto del artículo tiene la siguiente estructura: en la siguiente sección presentamos en detalle el modelo híbrido propuesto. La sección 2 describe la red neuronal de unidades producto propuesta en este artículo. En la sección 3, se prueba el rendimiento de dicha propuesta en diversos experimentos en un parque eólico español. Por último, la sección 4 finaliza el artículo estableciendo algunas conclusiones.

1.1. Modelo híbrido de predicción del viento con PUNNs

Existe un modelo híbrido de predicción del viento que ha dado muy buenos resultados en la predicción de la velocidad del viento en parques eólicos Españoles [8] (Figure 1). Específicamente, este modelo híbrido se basa en la mezcla de modelos de predicción global de mesoescala con modelos no lineales, fundamentalmente redes neuronales. En este artículo consideramos el modelo de predicción de viento híbrido que incluye un modelo de regresión tipo PUNN en su parte final. En la Figura 1 se muestra un esquema del modelo con un regresor genérico en su parte final. Como puede observarse, se parte de los datos de un modelo determinado de predicción global (hay diversos disponibles, la mayoría de acceso libre). Estas predicciones globales tienen una baja resolución (dan predicciones de variables meteorológicas en puntos distantes más de 100 Km), por lo que es necesario un proceso de *down-scaling*, para mejorar la resolución obtenida. Este proceso se lleva a cabo en dos pasos, primero se aplica un modelo de mesoescala, conocido como MM5, que es capaz de producir resultados en una malla de 15×15 Km, y posteriormente se aplica una regresión no lineal, usando un regresor para estimar la velocidad del viento en cada aerogenerador del parque. Este proceso es descrito en detalle a continuación.

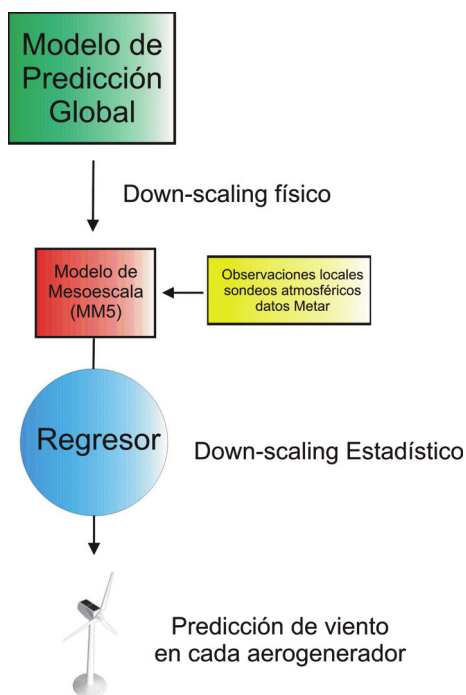


Figura 1: Diagrama ejemplo del sistema propuesto.

1.2. Predicciones globales y de mesoescala para estimación de la velocidad del viento

Un sistema de predicción global produce información meteorológica para tiempos futuros en determinadas posiciones y altitudes, considerando como dominio espacial toda la Tierra. Para llevar a cabo este proceso, el modelo resuelve las ecuaciones de Navier-Stokes, que gobiernan el comportamiento de la dinámica de la atmósfera. Estas ecuaciones son altamente no lineales, y por tanto imposibles de resolver de forma exacta, con lo que incluyen los efectos de caos espacio-temporal característicos de la atmósfera. Usualmente se utilizan métodos numéricos para integrar las ecuaciones de Navier-Stokes y obtener soluciones aproximadas. Los diferentes modelos globales de predicción usan diferentes métodos de integración, en la mayoría de los casos métodos de las diferencias fi-

nititas, o métodos espectrales. Además, se utilizan diversas medidas para inicializar los métodos de integración y como condiciones de contorno, fundamentalmente radiosondeos, medidas mediante globos atmosféricos, satélites climatológicos y observaciones en superficie en diferentes puntos del mundo. El resultado proporcionado por estos modelos globales son un conjunto de variables atmosféricas, tales como presión (P), temperatura (T), altura geopotencial (gdp) y, por supuesto, velocidad y dirección del viento (\mathbf{v}), para distintos instantes en el futuro. Normalmente, estas variables son obtenidas para un número de niveles de altura en cada punto (entre 1000 hPa y 10 hPa). En cuanto a la resolución espacial de los modelos, la mayor resolución horizontal hoy en día para un modelo global se proporciona en mallas de $0,25^\circ \times 0,25^\circ$, aunque lo usual es que los modelos proporcionen la predicción de variables en mallas de $1^\circ \times 1^\circ$ (aproximadamente 78 Km. en latitud y 110 en longitud). Por tanto, los modelos globales no tienen la suficiente resolución para ser usados en la predicción del viento en un parque eólico, y hay que llevar a cabo una serie de procesos, conocidos como *down-scaling* para aumentar la resolución de estas predicciones.

Un primer proceso de *down-scaling*, conocido como *down-scaling* físico, puede ser llevado a cabo utilizando un modelo de mesoescala, el MM5 [14]. El MM5 es lo que se conoce como un modelo de *escala limitada*. De la misma manera que los modelos globales, en el MM5 se integran las ecuaciones de Navier-Stokes que gobiernan el comportamiento de la atmósfera, pero en este caso no se incluyen las interacciones océano-atmósfera, claves en el caso de los modelos globales. El modelo MM5 toma los valores de predicción de los modelos globales como entrada, y los complementa con diferentes datos de observaciones provenientes de sondeos atmosféricos con globos aerostáticos, y con datos *metar*. Estos datos *metar* son datos de 39 aeropuertos de la península Ibérica y las islas Baleares, tomados cada 30 minutos en superficie. El modelo MM5 es capaz de realizar un buen *down-scaling* de las predicciones globales, proporcionando la predicción de

las variables atmosféricas con una resolución de 15 Km. \times 15 Km. Esta resolución mejora sensiblemente la obtenida por los modelos globales, pero aún es claramente insuficiente para la predicción de la velocidad del viento en un parque eólico, ya que es necesaria una predicción en cada uno de los aerogeneradores del parque.

De esta manera, el último proceso de *down-scaling* del modelo híbrido de predicción de velocidad del viento es un proceso estadístico, donde hay que utilizar un modelo de regresión para estimar la velocidad del viento en cada aerogenerador. Este último paso de predicción consiste entonces en aplicar un regresor (una red neuronal en este caso), a los datos provenientes del modelo MM5, para obtener el viento en cada turbina. En este artículo, como ha sido mencionado anteriormente, nosotros proponemos sustituir la red neuronal básica propuesta en [8] por una red de unidades producto (PUNN), que será entrenada por medio de un algoritmo de programación evolutiva con clustering (DHEPC) [15].

2. Redes de unidades producto evolutivas

2.1. Redes de unidades producto

El algoritmo base de regresión de este artículo está basado en una red de unidades producto (PUNN). Este tipo de modelos son una alternativa a los perceptrones multicapa que consideran unidades multiplicativas en los nodos ocultos, en lugar de unidades aditivas. Así, la salida de cada nodo oculto ($B_j(\mathbf{x}, \mathbf{w}_j)$) es la siguiente:

$$B_j(\mathbf{x}, \mathbf{w}_j) = \prod_{i=1}^m x_i^{w_{ji}}, \quad (1)$$

donde $\mathbf{w}_j = (w_{j1}, w_{j2}, \dots, w_{jm})$ es el vector de coeficientes para el j -th nodo oculto. El modelo propuesto es una combinación lineal de p de estas funciones base:

$$y = \beta_0 + \sum_{j=1}^p \beta_j \left(\prod_{i=1}^m x_i^{w_{ji}} \right), \quad (2)$$

donde $\mathbf{x} \in S \subset \mathbb{R}^m$ y S es un subconjunto del espacio real de dimensión m con $x > 0, \forall x \in \mathbf{x}$. El vector $\boldsymbol{\beta} = \{\beta_0, \beta_1, \dots, \beta_p\}$ representa el conjunto de coeficientes que multiplica cada una de las funciones de la base, y que están representados por el vector $\mathbf{B}_i = \{B_0(\mathbf{x}_i, \mathbf{w}_0), B_1(\mathbf{x}_i, \mathbf{w}_1), \dots, B_p(\mathbf{x}_i, \mathbf{w}_p)\}$, donde $B_0(\mathbf{x}, \mathbf{w}_0) = 1$ es el sesgo de la salida estimada, y \mathbf{w}_j es el vector de los coeficientes asociados a la j -ésima función base.

Para el conjunto de datos $D = \{\mathbf{x}_l, y_l\}$, con $l = 1, \dots, n$, el modelo de regresión puede entonces ser expresado por medio de una función de la forma:

$$\hat{y}_l = f(\mathbf{x}_l) = \beta_0 + \sum_{j=1}^p \beta_j \left(\prod_{i=1}^m x_i^{w_{ji}} \right) + e_l, \quad (3)$$

donde $l = 1, \dots, n$, $\beta_j, w_{ji} \in \mathbb{R}$ y e_l es el error obtenido para el patrón l -ésimo.

Hay que notar que en este caso, la estimación de los parámetros del modelo de regresión no es trivial, ya que la matriz de diseño $\mathbf{B} = \{\mathbf{B}_1, \dots, \mathbf{B}_n\}$ depende de los parámetros w_j y a su vez, los elementos de \mathbf{B} son funciones potenciales de los valores \mathbf{x} . Consecuentemente, se emplea un algoritmo híbrido para obtener el conjunto de valores óptimos de los coeficientes β_j y w_j . Hay que notar que la expresión dada por la Eq. ((2)) puede ser representada por una red neuronal, con la siguiente arquitectura: una capa de entrada, consistente en la salida del modelo MM5; una capa oculta con un número apropiado de neuronas y una capa de salida con una única salida que sería una estimación de la velocidad del viento.

2.2. Entrenamiento evolutivo de PUNN

El algoritmo evolutivo usado para el entrenamiento de los modelos PUNN tiene puntos en común con otros algoritmos de tipo evolutivo para la optimización de problemas con parámetros reales [16, 17]. El algoritmo comienza con una población inicial, y, en cada generación, la población se actualiza. La población se somete entonces a operaciones de réplica y mutación. En este caso, se incluyen dos operadores de mutación distintos, mutación paramétrica y mutación estructural, mientras que no

se incluyen ningún operador de cruce o recombinación (algoritmo de Programación Evolutiva puro, EP). En la mutación paramétrica, los valores de los coeficientes del modelo se cambian añadiendo un ruido Gaussiano a un gen del cromosoma elegido al azar. En la mutación estructural, la nueva solución se obtiene añadiendo o quitando nodos de la red, así como redefiniendo, añadiendo o quitando conexiones al modelo (coeficientes). Una discusión detallada de este tipo de mutaciones para el entrenamiento de PUNN pueden encontrarse en [13].

La búsqueda evolutiva es en este caso, intensificada mediante una serie de búsquedas locales. Se consideran dos búsquedas locales asociadas con el algoritmo evolutivo:

1. Optimización de la mejor solución final (HEPF): como primera aproximación a la búsqueda local, en este artículo se propone una búsqueda local implementada mediante un método quasi-Newton, el conocido algoritmo de Levenberg-Marquardt (L-M). En este caso, el L-M se aplica exclusivamente al mejor individuo obtenido en la búsqueda evolutiva en la generación final, y de esta manera se trata de mejorar el rendimiento de la EP con esta búsqueda local.
2. Programación Evolutiva dinámica con clustering (DHEPC): también analizamos una segunda posibilidad, consistente en incluir un procedimiento de *clustering*, y posteriormente una búsqueda local. El procedimiento de clustering se aplica a los mejores $\tilde{s} \cdot N_P$ individuos de la población, donde \tilde{s} es un parámetro del algoritmo. La población se divide en K clusters C_1, C_2, \dots, C_K , usando un algoritmo de K -medias estándar. El valor de K fue ajustado experimentalmente a $K = 4$ para toda la experimentación. Después, el algoritmo L-M se aplica como búsqueda local al mejor individuo de cada cluster. Los individuos optimizados para cada cluster son incluidos en un conjunto C (conjunto óptimo local). La combinación de clustering y búsqueda local es aplicada

de forma dinámica cada G_t generaciones, y en la generación final, con G_t fijado por el usuario. Los individuos obtenidos con la búsqueda local en cada cluster son incluidos en el conjunto C , y la solución final es el mejor individuo entre los individuos del conjunto C .

3. Experimentos y resultados

Para entrenar la red de unidades producto propuesta, las variables de entrada deben ser escogidas cuidadosamente. En este caso, como valores de entrada a la red se escogen las siguientes salidas del MM5: viento en dos puntos en los alrededores del parque eólico (s_1 and s_2), dirección del viento en un punto (d), temperatura en un punto (T). Estas variables se completan con dos variables temporales más que son una medida del ciclo solar, que está fuertemente relacionada con la circulación atmosférica:

$$H_1 = \sin\left(H \cdot \frac{2\pi}{24}\right) \quad (4)$$

$$H_2 = \cos\left(H \cdot \frac{2\pi}{24}\right) \quad (5)$$

donde $H = [0, 23]$. Nótese que las ecuaciones (4) y (5) expresan el ciclo solar durante 24 horas.

El sistema híbrido propuesto, incluyendo la red de unidades producto, ha sido aplicado a la predicción a corto plazo de viento de un conjunto de turbinas en el parque eólico de la Fuensanta, en Albacete, España. Datos de diversas turbinas desde Enero de 2006 a Junio de 2006 fueron obtenidos y procesados para eliminar los datos erróneos y las paradas de los aerogeneradores. Después de este proceso de filtrado, el diseño experimental ha sido llevado a cabo mediante un proceso de validación cruzada, mediante 30 experimentos por cada aerogenerador (aproximadamente 75% de muestras para el conjunto de entrenamiento y 25% para el conjunto de test). Entonces, hemos construido diversos conjuntos de entrenamiento para las diferentes turbinas consideradas (1, 7, 15, 21, 27 y 33) de 6273, 5768, 6284, 6284, 6049

y 6144 muestras, y test de 1569, 1443, 1572, 1572, 1513 y 1537, respectivamente.

3.1. Resultados

El Cuadro 1 resume el rendimiento de las diferentes técnicas consideradas en el problema de predicción de viento en la Fuensanta. La tabla muestra los valores medios (sobre 30 ejecuciones del algoritmo) de los errores *SEP* (*Standard Error of Prediction*) y *MSE* (*Mean Squared Error*), y también los errores del mejor de los modelos obtenidos se muestran en las últimas filas. Un resultado similar se incluye para el número de conexiones (#enl.) de los modelos obtenidos. Es fácil de ver que la PUNN con entrenamiento mediante DHEPC mejora (en términos de *SEP* y *MSE* medios) a los otros esquemas de entrenamiento implementados (EP y HEPF).

Para obtener una mayor validación de los resultados, se llevó a cabo una comparación con un perceptrón multicapa (MLP). Específicamente, el perceptrón descrito en [8]. Los resultados con diferentes números de neuronas se muestran en el Cuadro 2. Nótese que la red PUNN con entrenamiento DHEPC es capaz de mejorar los resultados del MLP considerado.

4. Conclusiones

Este estudio muestra la capacidad de las redes de unidades producto evolutivas (EPUNNs) para obtener predicciones de buena calidad en un problema de estimación de la velocidad de viento. Un sistema previo de estimación de la velocidad de viento [8] ha sido modificado y la parte del sistema final que realiza un down-scaling estadístico ha sido sustituida por un modelo EPUNN. De hecho, se han probado tres algoritmos de entrenamiento diferentes para la red (EP, HEPF y DHEPC) en diversos problemas reales de predicción de viento en aerogeneradores de un parque eólico en España. Hemos comprobado como el método de entrenamiento DHEPC es el que mejores resultados da, y como las EPUNN con este método mejoran el sistema de predicción de viento original, de forma que al comparar

los resultados con un perceptrón multicapa, el error del sistema es menor utilizando las redes de unidades producto evolutivas.

Referencias

- [1] A. Kusiak, H. Zheng and Z. Song, "Wind farm power prediction: a data-mining approach," *Wind Energy*, vol. 12, no. 3, pp. 275-293, 2009.
- [2] R.J. Barthelmie, F. Murray and S.C. Pryor, "The economic benefit of short-term forecasting for wind energy in the UK electricity market," *Energy Policy*, vol. 36, no. 5, pp. 1687-1696, 2008.
- [3] M. C. Mabel and E. Fernández, "Analysis of wind power generation and prediction using ANN: A case study," *Renewable Energy*, vol. 33, no. 5, pp. 986-992, 2008.
- [4] P. Louka, G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis and G. Kallos, "Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering," *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 96, no. 12, pp. 2348-2362, 2008.
- [5] G. Jia, X. Wuang and G. Wu, "Investigation on wind energy-compressed air power system," *Journal of Zhejiang University SCIENCE A*, vol. 5, no. 3, pp. 290-295, 2004.
- [6] S. L. Goh, M. Chen, D.H. Popovic, K. Aihara, D. Obradovic and D.P. Mandic, "Complex-valued forecasting of wind profile," *Renewable Energy*, vol. 31, pp. 1733-1750, 2006.
- [7] T.G. Barbounis, J.B. Theocharis, "Locally recurrent neural networks for wind speed prediction using spatial correlation," *Information Sciences*, vol. 177, pp. 5775-5797, 2007.
- [8] S. Salcedo-Sanz, Á. M. Pérez-Bellido, E. G. Ortiz-García, A. Portilla-Figueras, L. Prieto and D. Paredes, "Hybridizing the fifth generation mesoscale model with artificial

Cuadro 1: Resultados obtenidos con una red PUNN como regresor en el sistema completo de predicción de viento. Los resultados incluyen la Media y la Desviación Típica (DT) del error SEP y MSE y del número de enlaces asociados a los mejores modelos en un total de 30 ejecuciones. También se incluye el error MSE y el número de nodos del mejor modelo obtenido en las 30 ejecuciones.

| #Turbina | 1 | 7 | 15 | 21 | 27 | 33 |
|-------------------------|------------------|------------------|------------------|------------------|------------------|------------------|
| Error | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT |
| SEP_{EP} | 38.75 \pm 0.37 | 38.64 \pm 0.40 | 39.78 \pm 0.57 | 39.32 \pm 0.41 | 35.66 \pm 0.28 | 35.92 \pm 0.34 |
| SEP_{HEPF} | 38.61 \pm 0.55 | 38.45 \pm 0.47 | 39.81 \pm 0.47 | 38.83 \pm 1.21 | 35.36 \pm 0.38 | 35.85 \pm 0.47 |
| SEP_{DHEPC} | 38.58 \pm 0.56 | 38.44 \pm 0.49 | 40.02 \pm 0.66 | 38.86 \pm 1.22 | 35.36 \pm 0.32 | 35.89 \pm 0.49 |
| MSE_{EP} | 5.31 \pm 0.10 | 4.09 \pm 0.08 | 5.22 \pm 0.15 | 4.96 \pm 0.10 | 4.22 \pm 0.07 | 3.63 \pm 0.068 |
| MSE_{HEPF} | 5.27 \pm 0.15 | 4.05 \pm 0.10 | 5.23 \pm 0.12 | 4.84 \pm 0.32 | 4.15 \pm 0.09 | 3.62 \pm 0.09 |
| MSE_{DHEPC} | 5.26 \pm 0.15 | 4.05 \pm 0.10 | 5.28 \pm 0.18 | 4.85 \pm 0.32 | 4.15 \pm 0.08 | 3.63 \pm 0.10 |
| Enl. | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT | Media \pm DT |
| #enl. _{EP} | 19.80 \pm 4.16 | 19.53 \pm 3.51 | 27.10 \pm 2.82 | 25.30 \pm 2.42 | 26.17 \pm 2.67 | 25.33 \pm 2.43 |
| #enl. _{DHEPC} | 20.53 \pm 3.21 | 20.57 \pm 3.52 | 27.67 \pm 2.96 | 25.47 \pm 2.83 | 26.43 \pm 3.19 | 26.30 \pm 3.21 |
| | DHEPC | | | | | |
| MSE_{Mejor} | 5.02 | 3.91 | 4.91 | 4.59 | 3.99 | 3.44 |
| #nodos _{Mejor} | 5 nodos | 6 nodos | 6 nodos | 6 nodos | 6 nodos | 6 nodos |

Cuadro 2: Resultados obtenidos (MSE) con un perceptrón multicapa (MLP) como regresor en el sistema completo de predicción de viento comparados con los resultados obtenidos por el mejor modelo EPUNN encontrado con el algoritmo DHEPC. #NNO significa número de nodos en la capa oculta.

| #Turbina | MLP(#NNO) | | | | | | | EPUNN |
|----------|-----------|-------|------|------|------|------|------|-------|
| | 9 | 10 | 11 | 12 | 13 | 14 | 15 | |
| 1 | 5.70 | 5.64 | 5.62 | 5.67 | 5.64 | 5.61 | 5.74 | 5.02 |
| 7 | 4.27 | 10.05 | 7.14 | 4.25 | 4.28 | 4.27 | 7.48 | 3.91 |
| 15 | 5.15 | 5.13 | 8.09 | 5.13 | 5.13 | 5.11 | 5.12 | 4.91 |
| 21 | 5.09 | 8.33 | 8.35 | 5.03 | 5.06 | 5.03 | 5.03 | 4.59 |
| 27 | 4.44 | 4.46 | 4.46 | 4.42 | 4.43 | 4.44 | 4.45 | 3.99 |
| 33 | 3.91 | 3.90 | 3.90 | 3.93 | 3.91 | 3.92 | 6.48 | 3.44 |

- neural networks for short-term wind speed prediction," *Renewable Energy*, vol. 34, no. 6, pp. 1451-1457, 2009.
- [9] L. Landberg, G. Giebel, H. A. Nielsen, T.S. Nielsen and H. Madsen, "Short-term Prediction - An Overview," *Wind Energy*, vol. 6, no. 3, pp. 273-280, 2003.
- [10] S. Li, D. C. Wunsch, E. O'Hair and M. Giesselmann, "Comparative analysis of regression and artificial neural network models for wind turbine power curve estimation," *Journal of Solar Energy Engineering*, vol. 123, pp. 327-332, 2001.
- [11] M. A. Mohandes, T. O. Halawani, S. Rehman and A. A. Hussain, "Support vector machines for wind speed prediction," *Renewable Energy*, vol. 29, pp. 939-947, 2004.
- [12] J.L. Torres, A. García, M. De Blas and A. De Francisco, "Forecast of hourly average wind speed with ARMA models in Navarre (Spain)," *Solar Energy*, vol. 79, pp. 65-77, 2005.
- [13] A. Martínez-Estudillo, F. Martínez-Estudillo, C. Hervás-Martínez and N. García-Pedrajas, "Evolutionary product unit based neural networks for regression," *Neural Networks*, vol. 19, pp. 477-486, 2006.
- [14] J. Dudhia, "A nonhydrostatic version of the Penn State-NCAR Mesoscale Model: validation, tests and simulation of an atlantic cyclone and cold front", *Monthly Weather Review*, vol. 121, pp 1493-1513, 1993.
- [15] A. C. Martínez-Estudillo, C. Hervás, F. J. Martínez-Estudillo and N. García-Pedrajas, "Hybridization of evolutionary algorithms and local search by means of a clustering method," *IEEE Transaction on Systems, Man and Cybernetics, Part B: Cybernetics*, vol. 36, no. 3, pp. 534-546, 2006.
- [16] X. Yao and Y. Liu, "A new evolutionary system for evolving artificial neural networks," *IEEE Transactions on Neural Networks*, vol. 8, no. 3, pp. 694-713, 1997.
- [17] N. García-Pedrajas, C. Hervás-Martínez and J. Muñoz-Pérez, "Multiobjective cooperative coevolution of artificial neural networks," *Neural Networks*, vol. 15, no. 10, pp. 1255-1274, 2002.