



Asociación de Universidades  
GRUPO MONTEVIDEO



UNIVERSIDAD  
DE LA REPÚBLICA  
URUGUAY

# DESARROLLO DE HERRAMIENTAS PARA MANTENIMIENTO PREDICTIVO DE AEROGENERADORES EN BASE A REDES NEURONALES

Rodrigo Laguna <sup>a</sup>, Nicolás Geremías <sup>b</sup>, Luis Chiruzzo <sup>c</sup>, Diego Maiuri <sup>d</sup>, Julian  
Rodríguez <sup>e</sup>, Alejandro Gutierrez <sup>f</sup>, José Cataldo <sup>g</sup>

<sup>a</sup>Facultad de Ingeniería UdelaR, Uruguay, [rodrigo.laguna@fing.edu.uy](mailto:rodrigo.laguna@fing.edu.uy).

<sup>b</sup>Facultad de Ingeniería UdelaR, Uruguay, [ageremias@fing.edu.uy](mailto:ageremias@fing.edu.uy).

<sup>c</sup>Facultad de Ingeniería UdelaR, Uruguay, [luischir@fing.edu.uy](mailto:luischir@fing.edu.uy).

<sup>d</sup>Facultad de Ingeniería UdelaR, Uruguay, [dmaiuri@ute.com.uy](mailto:dmaiuri@ute.com.uy)

<sup>e</sup>Facultad de Ingeniería UdelaR, Uruguay, [jarodriguezf@ute.com.uy](mailto:jarodriguezf@ute.com.uy)

<sup>f</sup>Facultad de Ingeniería UdelaR, Uruguay, [aguti@fing.edu.uy](mailto:aguti@fing.edu.uy)

<sup>g</sup>Facultad de Ingeniería UdelaR, Uruguay, [jcataldo@fing.edu.uy](mailto:jcataldo@fing.edu.uy)

**RESUMEN:** El presente trabajo muestra una primera aproximación al desarrollo de un modelo de mantenimiento predictivo de grandes aerogeneradores de eje horizontal en base al uso de redes neuronales artificiales. El modelo de redes neuronales artificiales utiliza datos históricos medidos por diferentes sensores ubicados en los aerogeneradores, y a partir del entrenamiento de la red neuronal en períodos identificados como no afectados por problemas en la caja multiplicadora, se puede pronosticar, a partir de la diferencia de temperatura real y temperatura pronosticada, anomalías en la caja multiplicadora, identificando así un comportamiento no ideal previo a una falla. De este modo con la base de datos antes mencionada y el uso de redes neuronales artificiales, se busca detectar la probabilidad de incidencia futura de falla en la caja multiplicadora y así mejorar el proceso de mantenimiento y predicción de fallas en los aerogeneradores.

**PALABRAS CLAVE:** Inteligencia artificial, mantenimiento predictivo de aerogeneradores.

## 1 INTRODUCCIÓN

Uruguay en los últimos diez años incorporó un alto porcentaje de energía eólica en la matriz energética nacional. Esto hizo que el país desarrollara capacidades asociadas a la prospección energética, como la evaluación del recurso eólico disponible y el pronóstico de energía eólica, lo cual suministra informaciones imprescindibles para el despacho de energía eléctrica. Además fueron desarrolladas capacidades para la instalación de parques eólicos, desde el punto de vista logístico como de ingeniería civil, mecánica y eléctrica.

A todos estos factores se suma la necesidad de desarrollar capacidades de operación y mantenimiento de los parques eólicos, a modo de garantizar el menor tiempo posible de parada de la actividad de un parque eólico. El actual escenario muestra un conjunto de parques eólicos instalados en distintas regiones del país, los cuales tienen un conjunto muy diverso de fabricantes de aerogeneradores, que a su vez tienen distintos modelos.

A los efectos de poder gestionar la operativa y el mantenimiento de los parques eólicos se ha desarrollado un sistema centralizado de almacenamiento y visualización de las principales variables medidas por medio de una base de datos relacional. Este sistema cuenta con un registro histórico de las incidencias por fallas de los distintos componentes así como los valores de las diferentes variables registradas.

En los últimos años, la gestión de mantenimiento de aerogeneradores a nivel mundial ha recibido una mayor atención, con esfuerzos hacia la reducción de los costos de mantenimiento y tiempos de parada, centrándose los esfuerzos por un mantenimiento predictivo en lugar de un mantenimiento correctivo no programado [1].

Identificar los componentes críticos de un aerogenerador para hacer el mantenimiento estratégico es algo imprescindible. Diversos estudios han sido realizados, llegando muchos de ellos a la conclusión de que la caja multiplicadora es el componente crítico que causa el mayor tiempo de parada [2], [3], [4].

## 2 METODOLOGÍA

Para el desarrollo de un modelo de mantenimiento predictivo en base a redes neuronales artificiales se utilizaron medidas provenientes de diferentes sensores ubicados en el aerogenerador, los cuales a su vez miden distintas variables en diferentes puntos de los aerogeneradores. Se seleccionaron de dicha base de datos una serie de variables diez minutales reconocidas como críticas para la operación de la turbina. A su vez, se requiere disponer de un histórico de fallas relevantes de las turbinas, con el fin de marcar hitos en la vida de las máquinas que permitan diferenciar etapas con y sin fallas. El componente seleccionado para trabajar es la caja multiplicadora por ser el componente principal con mayor tasa de falla en el parque en estudio. Para la detección de esta falla se seleccionan las variables presentadas en la Tabla 1, con sus respectivas unidades de medida.

Variable	Unidad
Temperatura Ambiente	°C
Dirección del Viento Relativa	°
Velocidad del Viento	m/s
Potencia Activa	KW
Temperatura de la Góndola	°C
Velocidad de Giro del Rotor	rpm
Temperatura de Aceite de la Multiplicadora	°C

Tabla 1. Variables elegidas para el estudio.

El período de análisis fue desde el 1/7/2009 hasta el 5/10/2018. La variable a pronosticar fue la “Temperatura del Aceite de la Multiplicadora”, cuya diferencia entre el valor real y el valor pronosticado por la red neuronal artificial deberá ser estudiado a fin de detectar anomalías en el funcionamiento para el aerogenerador en estudio [5], [6]. Para realizar el pronóstico se utilizaron las siguientes variables de entrada: Temperatura Ambiente, Dirección del Viento Relativa, Velocidad del Viento, Potencia Activa, Temperatura de la Góndola y Velocidad de Giro del Rotor.

A continuación se presentan los daños en la multiplicadora para los dos aerogeneradores estudiados:

### **Aerogenerador 1**

25/03/2014: Daño en coronas de eje lento e intermedio de etapa helicoidal, detectado mediante inspección visual durante mantenimiento preventivo.

07/05/2015: Cambio de la multiplicadora.

### **Aerogenerador 2**

No presenta ningún tipo de falla.

A partir de estos datos, se definió un período de entrenamiento en el que el aerogenerador funciona correctamente. Para asegurar este punto, se deja un tiempo prudencial entre el período de entrenamiento y la falla detectada. Este período se utiliza para entrenar la red neuronal. Luego, se define un período de test, que tampoco incluye fallas, y es utilizado para verificar que el modelo aproxima correctamente la temperatura del aceite. Por último, el período en que la falla ocurrió, se denomina período de predicción, ya que es el período en el que se quiere predecir la falla.

Tanto las variables utilizadas para realizar la predicción como la temperatura a predecir, fueron normalizadas, de manera que al llegar a la red neuronal, estas tienen media cero y desviación estándar uno.

La red neuronal propuesta tiene una arquitectura completamente conectada con dos capas ocultas. La primera de ellas contiene 100 neuronas y la segunda 10. Tiene, además, una única neurona en su capa de salida, que se corresponde con la temperatura a predecir. La red neuronal propuesta, cuenta entonces con 111 neuronas y 1721 parámetros que deben ser ajustados.

Como función de activación se utilizó la tangente hiperbólica y para la función de costo a minimizar, se tomó el error cuadrático medio. La red fue entrenada mediante descenso por gradiente, utilizando el conocido algoritmo back propagation para el cómputo de los gradientes, y el algoritmo Adam [7] para minimizar la función de costo.

## **2.1 RESULTADOS**

A continuación son presentados los resultados obtenidos para cada uno de los aerogeneradores estudiados.

Para el aerogenerador 1, en el periodo de entrenamiento con los valores diez minutales, se logra un error cuadrático medio de 3.74, mientras que para el aerogenerador 2 fue de 3.36. En el periodo de test, el error fue de 4.98 y 4.25 respectivamente. Para el período de predicción, el error fue de 7.15 para el aerogenerador 1 y 3.84 para el 2.

Las figuras 1 y 2 muestran la diferencia del valor real y del valor pronosticado de la temperatura del aceite de la multiplicadora, promediada mensualmente. Para visualizar la tendencia que sigue la gráfica, cada punto representa el promedio de la diferencia de temperaturas durante los 15 días anteriores y los 15 posteriores. Se muestran en color verde los períodos de entrenamiento, en azul los períodos de test y en rojo los períodos de predicción. A su vez se indica en la figura 2 la fecha de detección de falla en la caja multiplicadora.

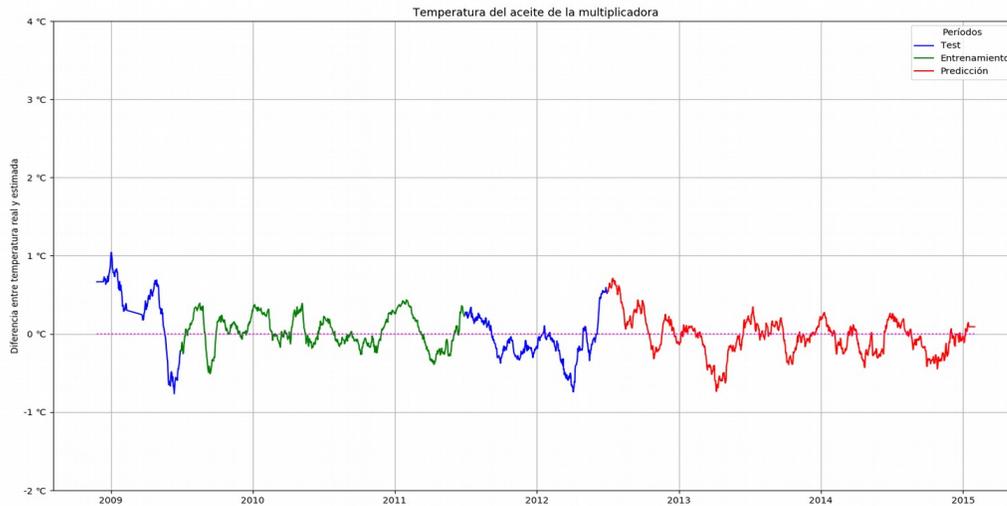


Figura 1. Valores mensuales estimados para el aerogenerador 2.

Puede observarse en la Figura 1, correspondiente al aerogenerador 2, que no presenta fallas en el período de tiempo estudiado, que la diferencia entre el valor real y el valor pronosticado de la temperatura del aceite de la caja multiplicadora se mantiene durante todo el período en un entorno muy cercano a cero (alcanzando como máximo 1°C).

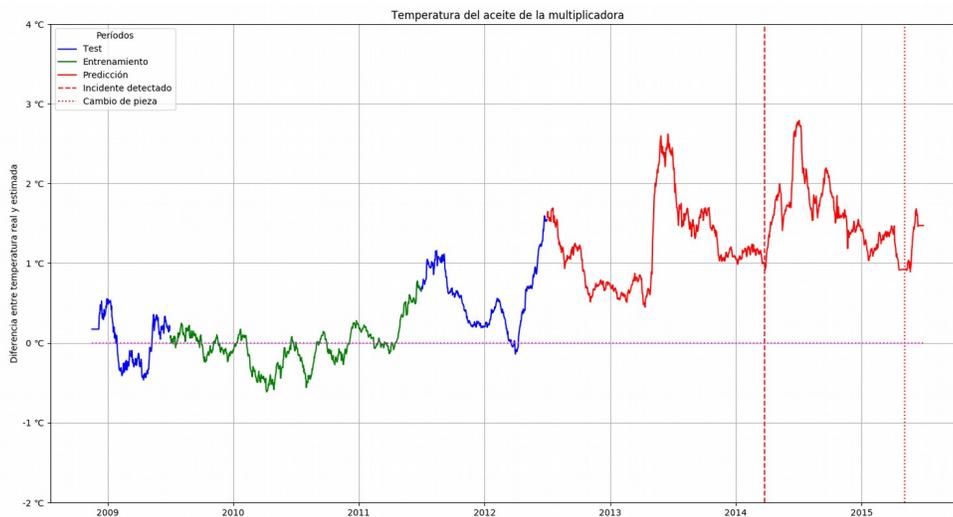


Figura 2. Valores mensuales estimados para el aerogenerador 1.

En la Figura 2 se muestra el aumento de la diferencia entre el valor real y el valor pronosticado de la temperatura del aceite de la multiplicadora, alcanzando valores cercanos a

3°C. Si bien la falla fue detectada el día 25/3/2014 puede apreciarse claramente una tendencia ascendente en la diferencia de temperatura desde mediados del año 2012.

Por otro lado se analizó el comportamiento de la temperatura del aceite de la caja multiplicadora en función de la velocidad del viento y de la potencia activa generada. En el primer caso se logró observar que a mayores velocidades de viento la temperatura presenta una menor variación. A partir de velocidades de viento de 12,5 m/s la temperatura del aceite se mantiene entre 50°C y 60°C, mientras que para velocidades menores la variación es mayor como se puede ver en la Figura 3. La figura presentada fue realizada a partir de datos correspondientes a el aerogenerador 1, pero se puede generalizar para cualquier aerogenerador ya que el comportamiento observado es el mismo.

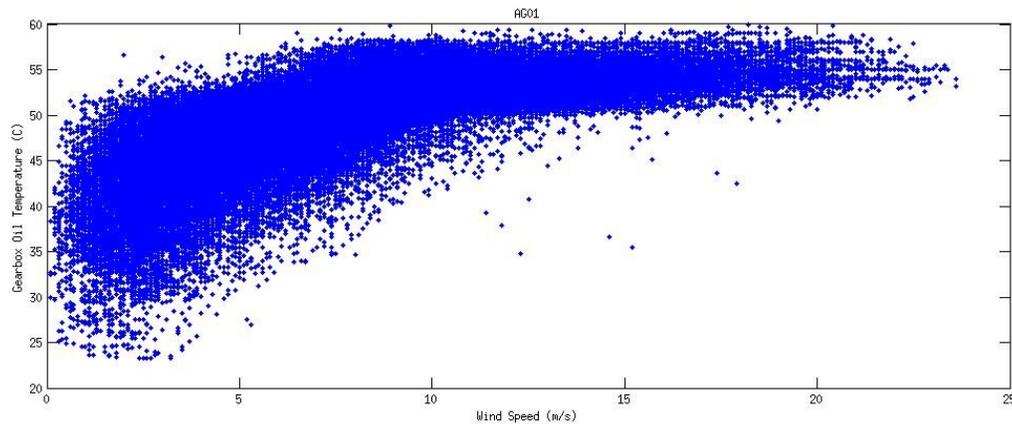


Figura 3. Temperatura del aceite de la caja multiplicadora en función de la velocidad del viento.

En el caso de la potencia activa, se puede observar un comportamiento similar al descrito anteriormente, ya que la potencia esta estrechamente vinculada con la velocidad del viento. Las altas temperaturas de aceite, entre 50°C y 60°C están asociadas a potencias mayores a 1 MW.

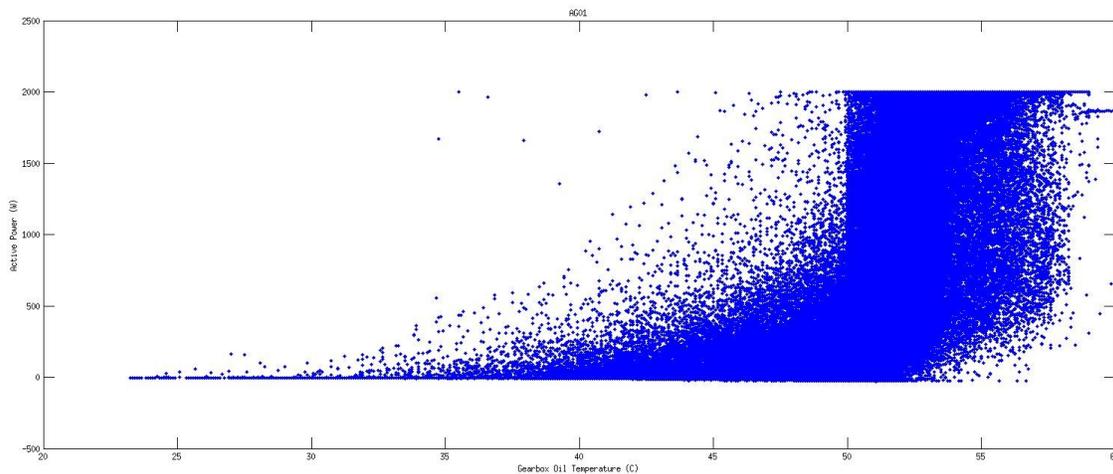


Figura 4. Potencia activa generada en función de la temperatura del aceite.

Teniendo en cuenta lo anterior y de manera de complementar los resultados mostrados en la Figura 1 y la Figura 2 se propone analizar el error residual, diferencia entre la temperatura real medida y la pronosticada por el modelo, a través de una serie de histogramas que muestran como

se distribuye el error antes mencionado. Se muestran en la Figura 5 y la Figura 6 los histogramas realizados para el aerogenerador 1 y 2 respectivamente. Cada histograma contiene aproximadamente 70 días de datos, para valores de potencia activa mayores a 500 kW.

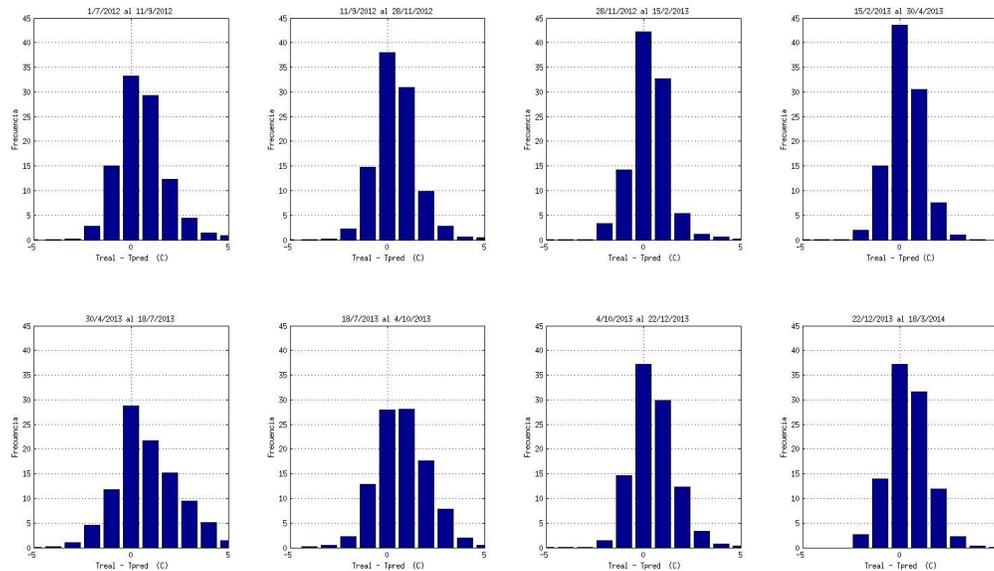


Figura 5. Error residual de la temperatura del aceite para el aerogenerador 1 entre el 1/7/2012 y el 18/3/2014.

En el histograma inferior izquierdo de la Figura 5, entre el 30/4/2013 y 18/7/2013 se logra apreciar un desplazamiento hacia valores mayores a 0°C del error residual, mientras que el resto de los histogramas muestran su media en 0°C con cantidades de casos de errores positivos y negativos muy similares. Este comportamiento anómalo de dicho histograma se corresponde con el pico observado en la Figura 2 en la misma fecha, en la cual el error residual alcanzó su máximo.

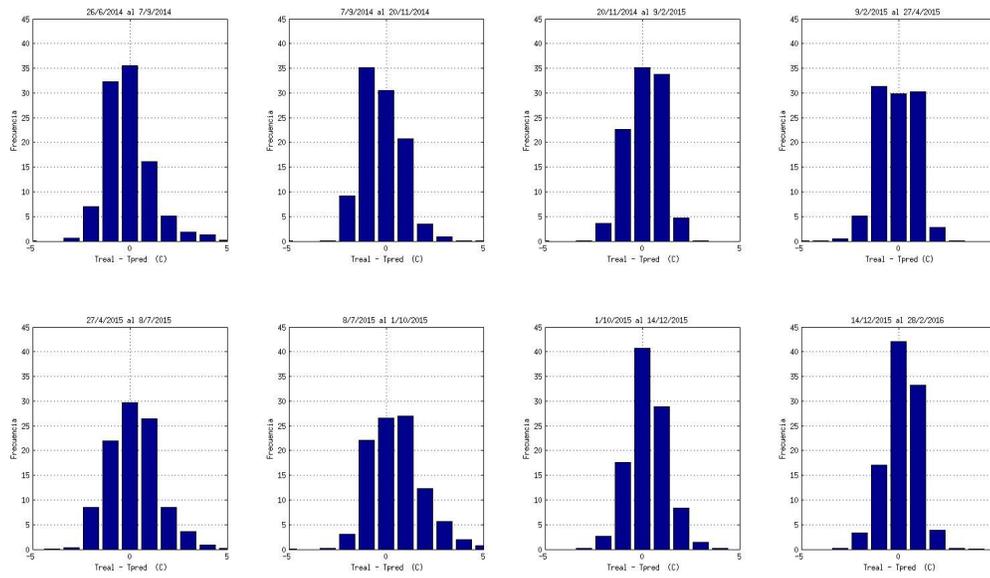


Figura 6. Error residual de la temperatura del aceite para el aerogenerador 2 entre el 26/6/2014 y el 14/12/2016.

A diferencia de la observación realizada anteriormente, en los histogramas de la Figura 6 el comportamiento es prácticamente en todos ellos, con la media en 0°C y la misma cantidad de casos con error residual positivo y negativo.

Se propone de esta manera para la detección de anomalías una salida gráfica de la red neuronal que muestre la media del error residual y su correspondientes percentiles de a un 5% y 95% como se muestra en la Figura 7.

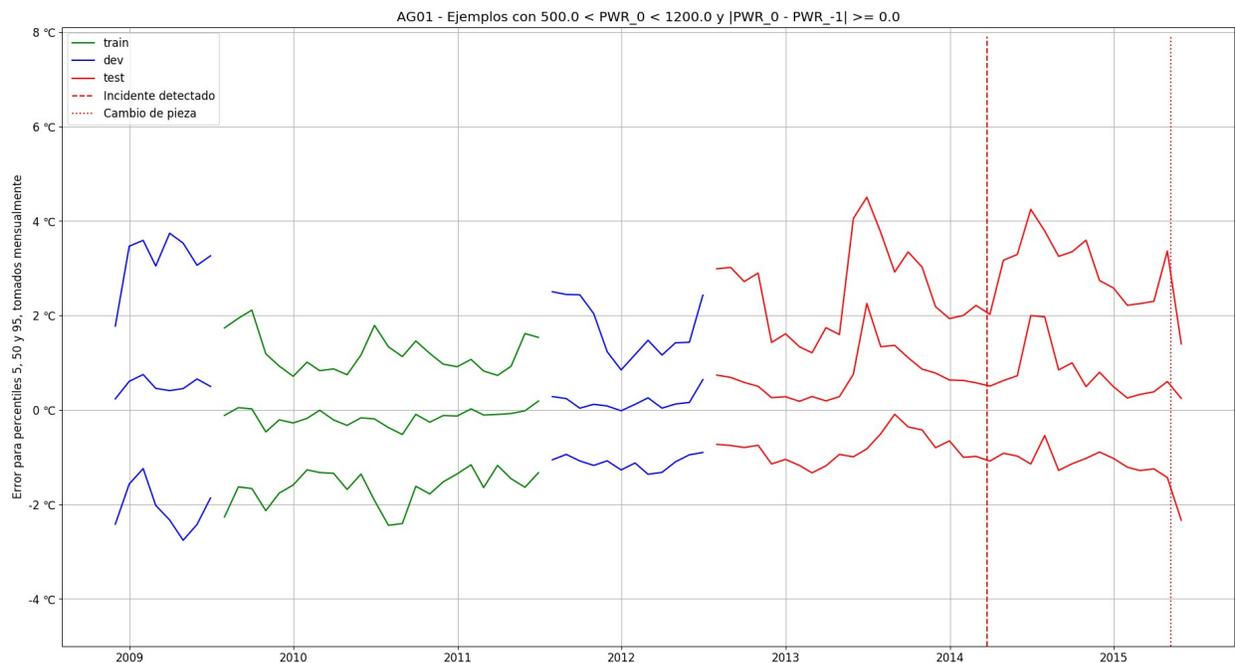


Figura 7. Media y percentiles 5% y 95% del error residual para el aerogenerador 1.

### 3 CONCLUSIONES

Los dos aerogeneradores estudiados tienen como principal diferencia que el aerogenerador 1 tuvo una falla en la caja multiplicadora, y el aerogenerador 2 no tuvo ninguna falla durante el período de análisis.

Utilizando redes neuronales artificiales entrenadas mediante descenso por gradiente se hizo un análisis de la diferencia de entre la temperatura real y la temperatura pronosticada por un modelo de redes neuronales previamente entrenado para cada aerogenerador en períodos sin anomalías en la caja multiplicadora.

Parece posible entonces identificar previamente problemas en la multiplicadora, permitiendo así planificar un mantenimiento predictivo de modo de evitar fallas en dicho componente del aerogenerador.

#### 4 REFERENCIAS

- [1] L. Bertling, R. Allan, and R. Eriksson, “A reliability-centered asset maintenance method for assessing the impact of maintenance in power distribution systems”, *IEEE Trans. Power Syst.*, vol. 20, no. 1, pp. 75–82, Feb. 2005.
- [2] J. Ribrant and L. M. Bertling, “Survey of failures in wind power systems with focus on Swedish wind power plants during 1997–2005,” *IEEE Trans. Energy Convers.*, vol. 22, no. 1, pp. 167–173, Mar. 2007.
- [3] F. Spinato, P. J. Tavner, G. J. W. van Bussel, and E. Koutoulakos, “Reliability of wind turbine subassemblies,” *IET Renew. Power Gener.*, vol. 3, no. 4, pp. 387–401, Dec. 2009.
- [4] S. Sheng, “Report on wind turbine subsystem reliability—A survey of various data-bases,” *Nat. Renew. Energy Lab.*, Washington, DC, USA, Tech. Rep. REL/PR-5000-59111, Jun. 2013.
- [5] P. Bangalore, L. Bertling, “An Artificial Neural Network Approach for Early Fault Detection of Gearbox Bearings”, *IEEE TRANSACTIONS ON SMART GRID*, VOL. 6, NO. 2, MARCH 2015.
- [6] Y. Hu, H. Li, X. Liao, E. Song, H. Liu, Z. Chen, “A probability evaluation method of early deterioration condition for the critical components of wind turbine generator systems”, *Mechanical Systems and Signal Processing* 76-77 (2016) 729–741.
- [7] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization”, *arXiv preprint arXiv:142,6980*, 2014.