



UNIVERSIDAD DE LAS PALMAS  
DE GRAN CANARIA

UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA

DOCTORADO EN EMPRESA, INTERNET Y TECNOLOGÍAS DE LAS  
COMUNICACIONES

**MODELOS DE PREDICCIÓN METEOROLÓGICA  
BASADOS EN MÉTODOS DE CLASIFICACIÓN  
ORIENTADOS A LA MEJORA DE LA EFICIENCIA  
ENERGÉTICA EN LOS PROCESOS DE GENERACIÓN**



**TESIS DOCTORAL**

**José Gustavo Hernández Travieso**

**Octubre de 2018**

**Las Palmas de Gran Canaria**









UNIVERSIDAD DE LAS PALMAS  
DE GRAN CANARIA

**D. Miguel Ángel Ferrer Ballester COORDINADOR DELPROGRAMA DE  
DOCTORADO Empresa, Internet y Tecnologías de la Información y  
Comunicaciones DE LA UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA,**

**INFORMA,**

Que la Comisión Académica del Programa de Doctorado,

en su sesión de fecha 12 de septiembre de 2018, tomó el acuerdo de dar el consentimiento para su tramitación, a la tesis doctoral titulada "Modelos de predicción meteorológica basados en métodos de clasificación orientados a la mejora de la eficiencia energética en los procesos de generación" presentada por el doctorando D. José Gustavo Hernández Travieso y dirigida por el Doctor D. Carlos Manuel Travieso González

Y para que así conste, y a efectos de lo previsto en el Artº 11 del Reglamento de Estudios de Doctorado (BOULPGC 7/10/2016) de la Universidad de Las Palmas de Gran Canaria, firmo la presente en Las Palmas de Gran Canaria, a doce de septiembre de dos mil dieciocho



**UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA**  
**ESCUELA DE DOCTORADO**

Programa de doctorado EMPRESA, INTERNET Y TECNOLOGÍAS DE LAS COMUNICACIONES

**Título de la Tesis**

**MODELOS DE PREDICCIÓN METEOROLÓGICA BASADOS EN MÉTODOS DE CLASIFICACIÓN ORIENTADOS A LA MEJORA DE LA EFICIENCIA ENERGÉTICA EN LOS PROCESOS DE GENERACIÓN**

Tesis Doctoral presentada por D. JOSÉ GUSTAVO HERNÁNDEZ TRAVIESO

Dirigida por el Dr. D. CARLOS MANUEL TRAVIESO GONZÁLEZ

**El Director,**

**El Doctorando,**

Las Palmas de Gran Canaria, OCTUBRE de 2018



*A mis padres...*

*y a tí por cambiarme la vida...*



## *Agradecimientos*

*“El saber a quién ves hace que la distancia no sea un problema...”*

*Quiero agradecer desde estas líneas a todas las personas que han ayudado a lo largo de toda mi vida a alcanzar este objetivo, algo que jamás llegué a imaginar cuando años atrás abandoné la carrera con la sensación de haber fracasado y de haber decepcionado...*

*Años después, al volver en un intento de probar si algo había cambiado en mí, pude comprobar que todo aquello que me generaba ansiedad y desesperación fue superado y logré el objetivo inicial...*

*Ahora, al acabar esta etapa formativa, miro hacia atrás y sé que todo ese camino de espinas, dudas y estrés valió la pena...*

*Teleco me ha cambiado la vida...*

*Muchas gracias a mis padres por todo el amor incondicional y el apoyo que siempre me han dado sin dejar de confiar en mis posibilidades...*

*Gracias a tí, que estás leyendo esto y sabes bien quién eres. El mundo es maravilloso gracias a tí...*

*Gracias a mi familia por estar siempre animando...*

*Gracias a mis amigos, los verdaderos, por ser amigos y estar ahí...*

*Gracias a mi Tutor/Director y acompañante en todo este camino a lo largo del PFC, TFM y Tesis Doctoral, Carlos Travieso por tus palabras, ánimo, dedicación, paciencia y comprensión...*

***GRACIAS A TODOS, SIN VOSOTROS NADA DE ESTO HUBIERA SIDO POSIBLE...***



## Índice

Introducción .....	1
Estado del Arte.....	3
Hipótesis .....	14
Objetivo.....	14
Metodología.....	17
Unidad temática de la Tesis Doctoral por Compendio de Publicaciones .....	26
Presentación de los trabajos publicados .....	28
Trabajos publicados.....	31
Resumen Artículo “Modeling a robust wind-speed forecasting to apply to wind-energy production” .....	33
Resumen Artículo “Neural networks fusion for temperature forecasting” .....	41
Resumen Artículo “Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development” .....	49
Modeling a robust wind-speed forecasting to apply to wind-energy production .....	57
Neural networks fusion for temperature forecasting .....	75
Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development .....	89
Discusión .....	109
Conclusiones.....	115
Bibliografía.....	121
Anexo I .....	131
Anexo II .....	133





## Índice de Ilustraciones

Ilustración 1: Ejemplo de nota explicativa de los datos de temperatura. ....	19
Ilustración 2: Ejemplo de datos contenidos en base de datos original.....	20
Ilustración 3: Ventana deslizante. ....	24
Ilustración 4: Diagrama de bloques del Modelo Predictivo. ....	28
Ilustración 5: Diagrama de bloques del Modelo Predictivo para el artículo Modeling a robust wind-speed forecasting to apply to wind-energy production.....	29
Ilustración 6: Diagrama de bloques del Modelo Predictivo para el artículo Neural networks fusion for temperature forecasting .....	29
Ilustración 7: Diagrama de bloques del Modelo Predictivo para el artículo Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development.....	30
Ilustración 8: Radiación solar en el Aeropuerto de Gran Canaria, utilizando el modelo predictivo entrenado para el Aeropuerto Tenerife Sur. ....	131
Ilustración 9: Velocidad del viento en el Aeropuerto de Tenerife Sur, utilizando el modelo predictivo entrenado para el Aeropuerto Gran Canaria. ....	132



## Índice de Tablas

Tabla 1: Dimensiones de los ficheros proporcionados por AEMET. ....	20
Tabla 2: Unidades en que se presentan los datos de la AEMET.....	21
Tabla 3: Número de muestras por estación y año. ....	23
Tabla 4: Unidades de los datos utilizados en los experimentos.....	25
Tabla 5: Comparativa de los resultados obtenidos en Predicción de Temperatura....	110
Tabla 6: Comparativa de los resultados obtenidos en Predicción de Velocidad del Viento.	
.....	110
Tabla 7: Comparativa de los resultados obtenidos en Predicción de Radiación Solar	111



## Glosario

- AEMET: Agencia Estatal de Meteorología.
- ANN: Red Neuronal Artificial (*Artificial Neural Network*).
- ARIMA: Modelo Autorregresivo Integrado de Media Móvil (*Autoregressive Integrated Moving Average*).
- ARMA: Modelo Autorregresivo de Media Móvil (*Autoregressive Moving Average*).
- BP: Propagación hacia atrás (Back-propagation).
- DBN: Red de Creencia Profunda (*Deep Belief Network*).
- DSS: Sistema de Soporte a las Decisiones (*Decision Support System*).
- ESN: *Echo State Network*.
- GA: Algoritmo genético (*Genetic Algorithm*).
- GC: Aeropuerto de Gran Canaria.
- IF: Índice de impacto (*Impact Factor*).
- JCR: *Journal Citation Report*.
- kJ/m<sup>2</sup>: Kilojulio por metro cuadrado.
- km: Kilómetro.
- km/h: Kilómetro por hora.
- kWh/ m<sup>2</sup>: Kilovatio hora por metro cuadrado.
- MAE: Error Medio Absoluto (*Mean Absolute Error*).
- mm: Milímetro.
- m/s: Metro por segundo.
- NWP: Predicciones Numéricas del Tiempo (*Numerical Weather Predictions*).
- sg: Segundo
- SVM: Máquina de Soporte Vectorial (*Support Vector Machine*).
- SVR: Regresión de Soporte Vectorial (*Support Vector Regression*).
- TF: Aeropuerto Tenerife Sur.
- W/m<sup>2</sup>: Vatio por metro cuadrado.



## Introducción

A raíz de la observación de las condiciones medioambientales existentes en Gran Canaria, donde es posible estar en Tejeda, la cumbre de la isla, con los pies en la nieve, cuando ésta llega, y ver al fondo el paisaje de las Dunas de Maspalomas con un sol radiante, surge la inquietud de intentar investigar la variabilidad climática existente en las Islas Canarias.

En las Islas Canarias se dan cada cierto tiempo una serie de alertas y avisos a la población por condiciones meteorológicas adversas que en ocasiones no causan los efectos pronosticados a priori, y viceversa, no se dan avisos y sin embargo se producen fenómenos que causan gran cantidad de daños.

Además, y fruto de la ubicación geográfica de las Islas Canarias, con zonas donde existen vientos fuertes y en las que el sol forma parte del coexistir diario de los canarios, se abre la posibilidad de generar energía mediante la utilización de fuentes renovables, mucho más limpias con el medio ambiente y sin la preocupación por su durabilidad como ocurre con las fuentes provenientes de combustibles fósiles.

Es por todo lo anteriormente expuesto, que surge la motivación de realizar un estudio de las condiciones meteorológicas para, a través de una eficiente y precisa predicción, servir de herramienta de apoyo en la generación de energías renovables.

Ante esta motivación se realiza un estudio acerca de los diferentes modos de realizar una predicción meteorológica. Se observa que éstas se realizan en su gran mayoría haciendo uso de imágenes satélite, imágenes radar y diversas herramientas de análisis matemático. Por tanto son medios costosos y que requieren de una infraestructura de grandes dimensiones, además de ser predicciones para unas zonas geográficas muy amplias.

Además este sistema será de predicciones a corto plazo, ya que queda comprobada la importancia de obtener predicciones precisas que cumplan esta característica en los procesos de generación energéticos [IIC, 2016a; IIC 2016b; ITC, 2018; ULL, 2018]

La presente Tesis Doctoral por Compendio de Publicaciones sigue la siguiente distribución.

En primer lugar, la Introducción, que contiene además el Estado del Arte, Hipótesis, Objetivo, Metodología, justificación de la Unidad temática de la Tesis Doctoral por Compendio de Publicaciones y Presentación de los trabajos publicados.

En segundo lugar se adjuntan los trabajos publicados. Habida cuenta de que han sido publicados en lengua inglesa, se presenta primeramente un resumen de cada uno de ellos en español. Seguidamente se añaden las copias de los trabajos contenidos en el Compendio de Publicaciones, y se termina con un apartado de Discusión.

En tercer lugar se presentan las Conclusiones de esta Tesis Doctoral, incluyendo las líneas futuras.

En cuarto lugar se muestra la bibliografía utilizada para la redacción de esta Tesis Doctoral por Compendio de Publicaciones.

Seguidamente, y para finalizar, se presentan los Anexos I y II.

Una vez acabada esta introducción, se continúa con el Estado del Arte

## Estado del Arte

Dentro de la gran cantidad de estudios realizados, y teniendo en cuenta que esta Tesis Doctoral es por Compendio de Publicaciones, se presentan los siguientes trabajos, incluyendo algunas patentes relacionadas:

En [Ellouz et al., 2009], se utilizaron Redes Neuronales Artificiales (*Artificial Neural Network*, ANN) para proponer una herramienta que ayudará a evaluar los aspectos del intercambio de calor entre el subsuelo y el aire a fin de lograr una mejora en las condiciones climáticas de un edificio de viviendas situado en la localidad tunecina de Sfax. Obtuvieron un error en las predicciones de 1°C. Logrando de este modo una mejora energética en las viviendas, ya que el consumo se ve reducido debido a la utilización de tuberías enterradas que consiguen refrescar o calentar el ambiente mediante el balance térmico del aire circulante por su interior.

En [Shu et al., 2010], se realizó un pronóstico de carga de los sistemas de generación eléctrica en una instalación del Medio-Oeste norteamericano en un área extensa considerando predicciones meteorológicas. Basándose en ellas, obtuvieron un pronóstico de carga bastante preciso, colaborando a la eficiente generación eléctrica en los momentos puntuales de mayor demanda energética.

En [Rastogi et al., 2011], se utilizó análisis de patrones para obtener una predicción de temperatura mediante ANN. Los resultados obtenidos, demostraron la eficiencia del modelo propuesto, consiguiendo una gran precisión del comportamiento de la representación de la predicción de temperaturas.

En [Chen y Xu, 2011], mediante la utilización de ANN, se realizó un modelo para la predicción de la temperatura y la humedad en las vías interiores de los túneles de las minas de carbón. Los resultados obtenidos tenían un rango de error del 0.2% al 4.9%, los cuales estaban dentro de los límites de precisión marcados por dicho proyecto.

En [Demirtas et al, 2012], se desarrolló un predictor de la radiación solar. Para ello se hizo uso de datos meteorológicos como humedad exterior, temperatura exterior, y presión barométrica para intentar predecir los niveles de radiación solar que pudieran

colaborar a la generación de energía fotovoltaica. La utilización de clasificadores basados en los k vecinos más cercanos, permitió obtener mejores resultados que otros estudios que hacían uso de otros tipos de clasificadores.

En [Routh et al., 2012], se estudió el uso de ANN para estudiar el impacto que sobre las células fotovoltaicas posee la temperatura. Con ello buscaban conseguir mejor eficiencia de las mismas, ya que es precisamente la temperatura uno de los factores que afectan a su correcto rendimiento. A la vista de los resultados obtenidos, se comprobó la efectividad de utilizar ANN para tal fin.

En [Vásquez et al., 2012], se desarrolló un sistema de predicción meteorológica basado en diferentes datos meteorológicos. Para ello utilizaron ANN multicapa, alcanzando muy buenos resultados, ya que la temperatura resultante de la predicción variaba en solo  $0.28^{\circ}\text{C}$  respecto a la real. En él se utilizó una base de datos con parámetros relativos a la época húmeda o no del año, parámetro importante teniendo en cuenta que se desarrolló en Costa Rica, que es un país tropical donde son éstas las épocas predominantes. De igual modo, contaba con datos precisos y continuados de radiación solar.

En [Huang et al., 2013], se utilizaron modelos basados en ANN para realizar una predicción de temperatura en diversas zonas del Aeropuerto de Adelaida (Australia). Esto es debido a que el comportamiento térmico de un edificio no es lineal, ya que puede variar de un punto a otro. En este estudio, el error obtenido fue de  $1^{\circ}\text{C}$ .

En [Bao et al., 2014], se propuso una estrategia de modelado basada en optimización por enjambre de partículas basada en múltiples entradas y salidas, que tenía la capacidad de determinar el número de sub-modelos en un modo auto-adaptativo, con predicciones variables. La estrategia se validó con datos reales y simulados.

En [Li X.F. et al., 2016], se utilizaron ANN para obtener la predicción de temperatura en el interior de un invernadero en la época estival en China. Los resultados obtenidos mostraban un error cuadrático medio de  $0.01^{\circ}\text{C}$ .

En [McKinney et al., 2015], se realizó una investigación para estudiar eventos climatológicos extremos, entre otros, temperaturas inusualmente altas y bajas. Alcanzaron un éxito superior al 90%.

En [Prashanthi et al., 2016], se propone un modelo predictivo capaz de obtener con entre 24 y 48 horas de antelación, temperaturas extremadamente altas utilizando para ello parámetros meteorológicos.

En [Aral y Guan, 2016] se comprueba la importancia de la temperatura superficial del mar en relación con el nivel del mar. Esto es debido a que estos parámetros están relacionados con el incremento del nivel del mar que se observa en la actualidad. A esta misma conclusión llegaron [Arora y Dash, 2016], el contraste de la temperatura del mar y el aire contribuye igualmente a alimentar el efecto destructivo de los sistemas de ciclones tropicales.

En [Pérez et al., 2016], se realiza una predicción de temperatura utilizando Máquinas de Soporte Vectorial (*Support Vector Machines*, SVM) obteniendo un error cuadrático medio de 0.09 °C.

En [Xingpei et al., 2009] se utilizan ANN para realizar predicciones de velocidad del viento, como mejor resultado y utilizando el algoritmo *back-propagation* (BP) con algoritmo genético (GA) fue de 1.33 metros por segundo (m/s) para una predicción a una hora.

En [Zhao et al., 2010] se utiliza Regresión de Soporte Vectorial (*Support Vector Regression*, SVR) y ANN con algoritmo BP para obtener una predicción de velocidad del viento. En el caso de ANN, el mejor resultado en términos de error medio absoluto (*Mean Absolute Error*, MAE) es de 1.21 m/s.

En [Tarade y Katti, 2011] se obtienen precisas predicciones de velocidad del viento haciendo uso de un Modelo Autoregresivo Integrado de Media Móvil (*Autoregressive Integrated Moving Average*, ARIMA), ANN y modelo de ajuste de curva polinómica. Con esto, obtuvieron un MAE de 2.24 m/s.

En [Bhaskar y Singh, 2012] se utiliza ANN con wavelet adaptativa y algoritmo *feed-forward* para obtener predicciones de energía eólica. En base a sus experimentos obtuvieron un MAE de 0.86 m/s.

Por su parte, [Shi et al., 2013] aplicaron ANN genética y *grey models* lograron mejorar las predicciones de velocidad del viento para su implementación en un parque eólico. Con ello, lograron un MAE de 0.51 m/s.

En [Chen et al., 2014], se realiza una investigación para obtener predicciones de velocidad del viento con un día de antelación combinando modelos numéricos y probabilísticos. En este estudio, el MAE obtenido fue de 1.24 m/s.

En [Hernández et al., 2014a], se hace uso de ANN para obtener una predicción de la velocidad del viento a corto plazo. El MAE obtenido fue de 0.84 m/s.

En el estudio de [Ruffin et al., 2009], hacen uso de un tipo de ANN con escasa conectividad de la capa oculta, llamada *Echo State Network* (ESN), para obtener predicciones de radiación solar para una ventana temporal que va desde los 30 a los 270 minutos desde el momento en que se realiza la predicción. En dicha investigación comprobaron que a medida que se alejaban en el tiempo de predicción, la precisión de la misma disminuía.

En [Naing y Srinivasan, 2010] utilizaron ANN y modelos de predicción matemáticos para obtener una estimación de la radiación solar utilizando para ello datos geográficos y meteorológicos. Obtuvieron una alta correlación entre los valores estimados obtenidos y los reales.

En [Wang et al., 2011] se utilizan ANN para obtener predicciones de radiación solar. Para el entrenamiento del sistema utilizaron datos de temperatura, índice de claridad y datos de radiación. Los resultados obtenidos indican que el método es apropiado para la predicción de radiación solar diaria.

En [Wu y Keong, 2011] se realiza la predicción de radiación solar haciendo uso de redes neuronales y Modelo Autorregresivo de Media Móvil (*Autoregressive Moving Average*, ARMA). La utilización conjunta de ambos métodos ofrece grandes resultados.

En [Zheng y Qiao, 2011] se propone un modelo basado en redes neuronales utilizando funciones de base radial para obtener predicciones de energía solar a corto plazo.

En [Yang et al., 2013] se propone un método de obtención de radiación solar utilizando SVM y utilizando técnicas de reconocimiento de patrones con distancia Euclídea.

En [Salcedo-Sanz et al., 2014] se estima la radiación solar haciendo uso de procesos de regresión Gaussianos. Los resultados muestran que el modelo es efectivo.

En [Hernández et al., 2014b], se realiza una predicción de radiación solar utilizando ANN obteniendo un MAE de 0.04 kilovatios hora por metro cuadrado ( $\text{kWh}/\text{m}^2$ ).

En [Gairaa et al., 2015] se presenta un método para la obtención de predicciones de radiación solar mediante redes neuronales para una zona de Argelia obteniendo un error del 7.55%.

En [Hernández et al., 2015] se presenta una nueva versión del estudio anterior en el que aplican diversos tipos de normalización para tratar de reducir la dispersión de las muestras y estudiar su efecto en la obtención de predicciones de radiación solar. Como resultado, se observó que el MAE se incrementó hasta los  $0.06 \text{ kWh}/\text{m}^2$ .

En [Baptista et al., 2016] se realiza una implementación *hardware* de una ANN para predecir la producción energética de un panel fotovoltaico. Con ello obtienen un error del 0.007%.

En [Koyasu et al., 2016] se utilizan imágenes del cielo para obtener predicciones de energía solar con una antelación de 1 o 2 horas.

En [Ghofrani et al., 2017] se desarrolla un modelo híbrido para realizar predicciones de radiación solar haciendo uso de minería de datos y redes neuronales.

En [Snegirev et al., 2017] se realiza la descripción matemática de un modelo de planta solar con predicciones de energía solar cada media hora utilizando modelos físicos y estadísticos.

En [Valverde et al., 2014] se realiza un estudio para la predicción de lluvias utilizando ANN en la región sudeste de Brasil. El método obtuvo resultados positivos. Siendo una herramienta interesante para salvar vidas alertando a la población de las lluvias, minimizando y evitando desastres, mejorando del mismo modo las condiciones de salud.

En [Houthuys et al., 2017] y haciendo uso de SVM, se realizan predicciones de temperatura en el campo de los pronósticos meteorológicos. Los resultados muestran la bondad del modelo empleado.

En [Mengquiao et al., 2017] se utiliza ARIMA y un tipo de red neuronal llamado Red de Creencia Profunda (*Deep Belief Network*, DBN) para realizar predicciones de mareas rojas en China. Uno de los varios parámetros medioambientales evaluados y utilizados para realizar esta predicción, entre los que se encuentran el pH, la salinidad del agua y el contenido de clorofila, es la temperatura. Con todos esos parámetros se realizan predicciones que son utilizadas para la posterior predicción de la marea roja.

En [Szeles et al., 2017] se muestra otra faceta importante en las aplicaciones de la predicción meteorológica. La implementación de un sistema que se integra en un robot que brinda asistencia a personas mayores. Con ello, el robot es capaz de ofrecer consejo a los ancianos sobre la ropa que deben usar al salir a la calle o de invitarles a dar un paseo si las condiciones climáticas son apropiadas, ayudándoles a realizar actividades acordes con la situación climatológica.

En [Andrade y Bessa, 2017] se propone un marco predictivo para explorar información de una red de Predicciones Numéricas del Tiempo (*Numerical Weather Predictions*, NWP) en la zona de Galicia y Portugal aplicadas a la generación eólica (Galicia) y solar (Portugal). Para ello utilizan árboles de decisión obteniendo resultados que muestran que, aunque la aproximación es buena, es necesario mejorar el tiempo de investigación en el campo de la minería de datos para obtener mejores resultados.

En [Sagar et al., 2017] se presenta un análisis que evalúa la habilidad de NWP en la predicción de tormentas de lluvia en India. Comprobaron que las predicciones estaban

de acuerdo con las observaciones hasta 2 días vista, incrementándose los errores a partir de ese punto temporal.

En [Allen et al., 2017] aplicaron un método de escalado de capa límite para predecir la velocidad del viento y la potencia cerca de la superficie. Con ello obtuvieron un error en las predicciones de densidad de potencia de un 1%.

En [Murata et al., 2018] se desarrolla un nuevo modelo empírico para modelar la incertidumbre en las predicciones de irradiación solar con NWP.

En [Cramer et al., 2017] se realiza una evaluación de 7 métodos de *machine learning* para realizar predicciones de lluvia utilizando datos de Estados Unidos, Holanda, Suiza, Alemania, Eslovenia, Luxemburgo, Francia, España y Portugal. Los resultados muestran los efectos positivos de estas técnicas de *machine learning* para realizar dichas predicciones en base a la precisión de los resultados obtenidos y la mínima correlación existente entre los climas evaluados.

En [Donida et al., 2018] se presenta un Sistema de Soporte a las Decisiones (*Decision Support System*, DSS) capaz de hacer predicciones de producción de energía eléctrica, estimar el índice de variación de la predicción y analizar las características de producción del parque eólico. Siendo su contribución el obtener dicha predicción haciendo uso de variables meteorológicas.

En [Refaat et al., 2018] se propone la posibilidad de desarrollar una relación fiable entre el sistema generador de energía fotovoltaica y la eficiencia con varios factores meteorológicos como la irradiancia, la temperatura, el polvo y el viento haciendo uso de ANN. En sus simulaciones obtuvieron una precisión del 99.9%.

Otra muestra más de la importancia de la meteorología a la hora de gestionar los recursos energéticos se aprecia en [Jian et al., 2018], en donde tienen en cuenta los factores climáticos a la hora de realizar las previsiones de demanda energética en Tianjin (China). Incluir estos datos mejora la precisión de la previsión de la demanda.

También en el estudio de [Lin et al., 2018] se tiene en consideración el efecto acumulado de la temperatura ambiente en la realización de la predicción de carga

máxima diaria de la red energética. Como conclusión comprueban la dependencia de los factores meteorológicos en la carga diaria máxima de la red eléctrica.

En [Eroshenko y Khalyasmaa, 2018] se realiza una metodología de predicción a corto plazo para obtener energía en plantas solares desarrollado sobre la base del análisis de regresión. En su estudio comprobaron la existencia de un error en el caso de días nublados que hacía necesario la creación de un modelo específico para días nublados.

En [Xiao y Ai, 2018] se estudian las perturbaciones en la calidad de la energía a través de Modelos Multi-ocultos de Markov, para obtener herramientas de prevención de dichas perturbaciones. Para ello utilizan también la información meteorológica, ya que, como comprobaron, su inclusión mejora la precisión de la predicción.

En [Luo et al., 2018] se realiza un estudio para la predicción de la velocidad del viento haciendo uso de métodos de *extreme learning machine* y de *deep learning*. Estos modelos permiten atacar la ANN con una mayor rapidez. Aunque sus resultados son buenos, reconocen que para mejorar el rendimiento de este modelo aún queda mucho trabajo por realizar. Con ANN obtuvieron como mejor resultado en términos de MAE 0.667 m/s.

En [Khodayar et al., 2018] se realiza un estudio para obtener la predicción de la velocidad del viento en un rango de tiempo entre 1 y 24 horas de adelanto. Para ello hacen uso de técnicas de *deep learning* usando *Tensorflow*. Los resultados obtenidos para un horizonte temporal inferior a los 10 minutos el sistema puede ser considerado como *offline* utilizando el histórico de datos.

En otro estudio de [Khodayar y Wang, 2018] se utiliza nuevamente *deep learning* para realizar predicciones de velocidad del viento. En este caso la zona bajo estudio se localizó en el noreste de los Estados Unidos a lo largo de 145 ubicaciones con una base de datos de 6 años y 5 minutos de frecuencia de muestreo. Realizaron el entrenamiento del sistema con el 80% de las muestras y el test con el 20% restante. Para una predicción a 1 hora de adelanto el mejor MAE que obtuvieron fue de 0.533 m/s.

En [Wu Y.K. et al., 2018] se realiza una predicción probabilística de potencia eólica. Ésta se ha tenido en cuenta en las últimas una o dos décadas como una entrada más a la hora de la toma de decisiones para obtener una penetración económica y fiable de las energías renovables.

En [Kaiju et al., 2018] se realiza una predicción de energía fotovoltaica haciendo uso de técnicas de lógica difusa. Indican que, a la hora de obtener energía solar influyen no solo factores medioambientales como la temperatura ambiente, la irradiancia y la velocidad del viento. También influyen factores como la temperatura y localización de los componentes de la instalación. La potencia de salida de la instalación está caracterizada por una alta intermitencia y volatilidad entre otros factores. Los resultados de sus simulaciones obtienen un error que se mantiene dentro del 8%.

En [Wu F. et al., 2018] realizan un modelo para predecir la energía undimotriz obtenida a través de las olas y de la fuerza del viento. Las olas están impulsadas por el viento, por ello la relación entre el viento y las olas es muy útil en dicha predicción. Para ello se analiza, entre otros factores, la correlación entre el viento y la ola. Los resultados de las predicciones realizadas a un día vista, comparados con los niveles de energía reales obtenidos, validan la efectividad del método propuesto.

En [Shi et al., 2018] queda de manifiesto que la importancia de los factores climatológicos también es importante en la producción industrial. Unas condiciones estables, precisas y confiables de temperatura y humedad mejoran la productividad. Con ello se consigue una mejor gestión y efectividad de los sistemas de control de aire acondicionado. Más aún en el caso concreto de este estudio realizado en una fábrica de tabaco en China.

En [Zhang T. et al., 2018] se presenta un modelo predictivo de control energético para la regulación de los sistemas de climatización de un edificio, permitiendo a su vez una reducción del consumo energético de los mismos. Para lograrlo también hacen uso de los valores de las condiciones meteorológicas de la ubicación del mismo (Singapur). Factores como la ocupación de diversas zonas o no del edificio hacen necesario controlar las condiciones ambientales de dichas dependencias para lograr una sensación térmica

confortable. Con un edificio inteligente con sensores integrados, además de la inclusión de las condiciones climáticas existentes en esos instantes, este modelo puede ser posible.

En [Du et al., 2018], para controlar y reducir los consumos energéticos del edificio en relación con los sistemas de climatización, se tienen en consideración las predicciones meteorológicas existentes en el exterior del mismo. Pero al existir errores en esas predicciones, este estudio realiza un ajuste de dichos errores para reducir así el consumo energético del edificio localizado en Austin (Texas, Estados Unidos). Haciendo uso de este método lograron reducir el gasto energético del mismo.

En [Lin y Weng, 2018] se utiliza información vía satélite para realizar la estimación de la velocidad máxima del viento en los huracanes. Para ello se hace uso además de la información de anomalías térmicas a cada nivel de presión dentro del huracán se deriva respecto a su entorno. Esto es, está comprobado que cuando un ciclón entra en la etapa de convertirse en huracán, en la parte alta de la Troposfera ocurre una anomalía térmica en la que se produce un incremento de temperatura. De la información obtenida del GPS de las dropsondas utilizadas en los huracanes Harvey, Irma y María en 2017, se comprueba una relación lineal entre una mayor temperatura de la anomalía con una mayor velocidad del viento.

En [Zhang B. et al., 2018] se realizan predicciones meteorológicas para poder tener datos certeros y fiables a la hora de realizar vuelos con aeronaves no tripuladas. La relación entre las condiciones meteorológicas y la planificación de misiones y análisis de riesgo con aeronaves no tripuladas está suficientemente documentado en la literatura. Es por ello que un análisis más fiable, preciso y flexible de las condiciones meteorológicas es deseable para tal fin.

En [Yoshida et al., 2016] se describe la predicción de la fluctuación de la velocidad del viento usando redes neuronales. Con este método obtienen una precisión en la predicción de las fluctuaciones del 59% y una precisión en la predicción de velocidad del viento del 43%.

En [Mert et al., 2016] se utilizan ANN para estimar la producción energética de un aerogenerador. El estudio se desarrolló en Turquía haciendo uso de los datos del servicio meteorológico estatal. Pudieron observar que los modelos de ANN ofrecen mejor rendimiento para parámetros meteorológicos compuestos por regresión multilínea paso a paso.

En [Li J. et al., 2016] se utiliza GA con ANN BP para obtener predicciones de velocidad del viento. El MAE alcanzado con este método es de 0.547 m/s.

En [Filik y Filik, 2017] se obtiene una predicción de velocidad del viento haciendo uso de ANN a partir de múltiples datos obtenidos en Turquía. Los datos provienen de un sensor localizado en una vivienda inteligente que se utilizó como laboratorio de pruebas en una determinada ubicación y un lugar específico. Los resultados obtenidos presentan un MAE de 0.503 m/s.

En [Ulkat y Günay, 2017] se obtienen predicciones medias de velocidad del viento y optimización de energía eólica en Turquía utilizando ANN con datos del sistema de archivo de datos meteorológicos turco. Con ellos, obtienen un MAE de 0.32 m/s.

Seguidamente, se presentan algunas patentes relacionadas con la predicción meteorológica.

En las siguientes patentes se obtienen las predicciones meteorológicas en base a imágenes de radares meteorológicos US 7076368 B2 [Wada, 2006], US 8625840 B2 [Ravela et al., 2014].

En la patente US 7728759 B2 [Tillotson et al., 2010] se hace uso de imagen satélite y de la información temporal suministrada por el mismo para obtener la información meteorológica.

En la patente US 8818029 B1 [Mecikalski et al., 2014] se utiliza imagen satélite para obtener la información.

En la patente US 8100004 B2 [Young et al., 2012] se hace uso de sensores barométricos acoplados a GPS para obtener la predicción.

En las patentes US 8095315 B2 [Artis, 2012], US 20070179703 A1 [Souissiel et al., 2007] los datos son obtenidos en vuelo por las aeronaves.

## Hipótesis

Tras observar la diversidad de estudios realizados en la materia presentados en el apartado anterior, y viendo la existencia de un vacío en cuanto a la posibilidad de mejorar tanto la precisión como reducir el equipamiento tecnológico necesario para obtener predicciones meteorológicas, surgen una serie de inquietudes que cristalizan en una hipótesis que se pretende demostrar.

La hipótesis sobre la que se centra esta Tesis Doctoral es la siguiente:

*“La obtención de predicciones meteorológicas que permitan caracterizar la variabilidad climática, reduciendo al mínimo el error existente entre la predicción y la medida real, proporciona a los procesos de generación energética un potencial que permite la mejora en la eficiencia de los procesos de generación y previsión energética mediante velocidad del viento y radiación solar.”*

## Objetivo

En base a la hipótesis presentada previamente, es necesario marcar un objetivo que permita su demostración. Estos objetivos permitirán desarrollar un entorno de trabajo para validar y concluir la hipótesis definida.

El objetivo de esta Tesis Doctoral consiste en la realización de un modelo de predicción meteorológica que se diferencia de lo actual en que será un modelo a nivel microscópico y de corto plazo, unas pocas horas de antelación, y que permita mejorar la eficiencia en los procesos de generación de energía, tanto mediante fuentes renovables (eólica y solar) como mediante combustibles fósiles.

Esto es, frente a las predicciones que dan los valores de magnitudes climáticas para áreas grandes, este modelo intentará lograr predicciones en las zonas específicas en las cuales se hayan instalado una serie de estaciones meteorológicas que den aporte de datos a este modelo predictivo. Con lo que se logra mejorar dos aspectos de los métodos empleados en la actualidad, se realiza para una zona específica y se reducen considerablemente los costes económicos a la hora de realizar la predicción. Logrando como consecuencia, la caracterización de la variabilidad climática de la zona en estudio.

Esta Tesis Doctoral se ajusta dentro de la segunda línea de investigación del Programa de Doctorado en Empresa, Internet y Tecnologías de las Comunicaciones (EmITIC), titulada “Sociedad, empresa y Tecnologías de la Información y el Conocimiento” en los temas siguientes:

- Computación adaptativa y neurociencia computacional.

Debido a los sistemas de clasificación empleados se desarrolla una tarea de neurociencia computacional y computación adaptativa.

- Organización, comportamiento humano y sostenibilidad.

Al colaborar a la mejora de la eficiencia energética colabora con la sostenibilidad del medio ambiente, encontrándose encuadrada en este tema.

- Inteligencia artificial.

Debido a los sistemas de clasificación empleados.

- Procesado de señal.

Los datos son clasificados y tratados como señales.

Desarrollando un poco más el objetivo de esta Tesis Doctoral, hay que tener en cuenta una serie de factores que se dan en las predicciones meteorológicas en la actualidad. Tal como ha quedado comprobado en el estado del arte, para obtener una predicción meteorológica, los datos se obtienen de muy diversas formas, pero en ellas se realiza modelado matemático, se utilizan sensores de tipo radar y/o imágenes vía

satélite entre otros. Además de costosos en términos de infraestructura y materiales necesarios, estos modelos son aplicables a grandes áreas con lo que se pierden detalles en zonas específicas que pueden tener una importancia vital a la hora de por ejemplo, poder atacar un incendio forestal o poder prever los riesgos ocasionados por unas lluvias intensas en un intervalo corto de tiempo que ocasionan gran cantidad de daños.

Frente a estos modelos, el modelo propuesto como objetivo de esta Tesis Doctoral, versará sobre un modelo aplicado a una zona de estudio concreta, con lo que se obtiene certamente y con alta fiabilidad la caracterización de la variabilidad climatológica de la zona bajo estudio para un horizonte temporal cercano, esto es unas pocas horas de antelación. El modelo es altamente efectivo para horizontes temporales de 1 hora de antelación (tal como queda demostrado en los artículos publicados que forman este Compendio de Publicaciones). Además, la reducción de costes en infraestructuras y materiales con respecto a los modelos actuales es otra clara ventaja del modelo.

Este modelo pretende colaborar en la generación de energías renovables colaborando tanto con las grandes plantas solares y/o parques eólicos, como con los pequeños productores que instalen en sus domicilios y/o empresas los sistemas de generación de energías limpias. La consecución de esta meta es posible gracias a las predicciones certeras, fiables y rápidas que este modelo predictivo es capaz de ofrecer, con lo que puede lograrse una mejora en la eficiencia en el proceso de generación. La gran ventaja es que el modelo es aplicable a todos y cada uno de los paneles fotovoltaicos y aerogeneradores del mercado, ya que puede convertirse en un producto de valor añadido a los mismos.

Del mismo modo, puede servir de valor añadido al sector turístico, permitiendo al sector ofertar a sus clientes una seguridad del estado del clima a la hora de la realización de una ruta turística por ejemplo. También a las explotaciones agrícolas y ganaderas a la hora de planificar riegos o de recoger al ganado ante la proximidad de un fenómeno meteorológico adverso.

El que podría ser el eje central de las aplicaciones de esta Tesis Doctoral es el relativo a la generación energética, como anteriormente se indicaba en un breve esbozo. Habida cuenta de que en la actualidad el combustible fósil es la principal fuente empleada en la generación energética y que estas fuentes llegarán a agotarse en un momento dado, se hace necesario observar las fuentes de energía limpia como actores de importancia en la generación eléctrica. Es ahí donde este modelo predictivo pretende colaborar decididamente, permitiendo obtener una predicción certera que ayude a una mejor y mayor eficiencia de estos sistemas generadores. Con ello se colaboraría a reducir emisiones de CO<sub>2</sub> y a la utilización y aprovechamiento de energías limpias.

Explicando la historia de esta Investigación, los orígenes se remontan al año 2013, en el que se obtiene la Beca INNOVA Canarias 2020 otorgada por la Fundación Universitaria de Las Palmas y con el mecenazgo de la Fundación Endesa. En el año 2014 se realiza el Trabajo Fin de Master siguiendo esta línea y se obtiene un sistema capaz de realizar predicciones de temperatura. Pero es a partir de ese momento en el que se empiezan a vislumbrar las múltiples posibilidades, variantes, variables y aplicaciones que un modelo predictivo de estas características puede llegar a tener.

## Metodología

Antes de entrar en profundidad en la parte metodológica en que se basa esta Tesis Doctoral, es necesario presentar brevemente las partes que la forman.

En primer lugar, se presenta la base de datos que se utiliza (origen, datos y estructura de la misma, etc.). A continuación se introduce el sistema de clasificación empleado en los artículos que forman este Compendio de Publicaciones y se hace un breve comentario de los diversos sistemas de clasificación empleados a lo largo de esta Investigación.

Seguidamente se comenta ya el aspecto metodológico propiamente dicho, formado por las diversas etapas a seguir para obtener la predicción meteorológica de

interés. Estas etapas son preprocesado, adaptación de datos para su introducción en entorno Matlab y realización del banco de pruebas.

El Departamento de Señales y Comunicaciones de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria, dispone de una base de datos meteorológicos de pago proporcionada por la AEMET, agencia que depende del Ministerio de Transición Ecológica y que anteriormente dependía del Ministerio de Agricultura, Alimentación y Medio Ambiente del Gobierno de España.

El motivo de seleccionar la información de esta base de datos es, a parte de la disponibilidad inmediata de un repositorio de datos meteorológicos de 5 años de duración, la fiabilidad y confiabilidad de las mediciones ofertadas por la AEMET.

En la misma se presentan datos obtenidos en las estaciones que la AEMET tiene instaladas en el Aeropuerto de Gran Canaria y en el Aeropuerto de Tenerife Sur, obtenidos entre los años 2003 a 2007 (5 años), ambos inclusive. En ella se recogen datos relativos a las siguientes variables meteorológicas:

- Humedad.
- Meteoro.
- Nubosidad.
- Precipitación.
- Radiación.
- Temperatura.
- Viento.

Los datos se presentan en formato .xls de Microsoft Excel, perteneciente al paquete Microsoft Office. En cada uno de los ficheros que forman la base de datos, se presentan los datos de cada fenómeno de manera conjunta para ambas estaciones. Esto es, en una hoja Excel se presentan los datos de, por ejemplo, temperatura correspondientes a las estaciones del Aeropuerto de Gran Canaria (GC) y Aeropuerto de Tenerife Sur (TF), para el periodo de 5 años indicado anteriormente. Y así con todos y cada uno de los fenómenos meteorológicos anteriormente citados.

Para comprender correctamente los datos contenidos en cada hoja Excel, éstas vienen acompañadas de un fichero en formato .txt en el que se recogen las indicaciones del contenido de cada campo del archivo Excel. Se recogen las indicaciones relativas a indicativo climatológico, nombre y altitud de la estación, provincia, longitud y latitud, valor de la variable contenida en la hoja Excel para las 24 horas del día, valores máximos y mínimos acompañados de la hora en que se produjeron. Además de la información de día, mes y año en que se toma la muestra.

Un ejemplo de este fichero se muestra en la siguiente ilustración.

Campos incluidos:  
Indicativo: Indicativo climatológico  
NOMBRE: Nombre estación  
ALTITUD: Altitud de la estación  
NOM\_PROV: Provincia  
LONGITUD: Longitud geográfica  
(La última cifra indica la orientación: 1 para longitud E y 2 para W)  
LATITUD: Latitud geográfica  
  
T00: Temperatura a las 00  
T01: Temperatura a las 01  
T02: Temperatura a las 02  
T03: Temperatura a las 03  
T04: Temperatura a las 04  
T05: Temperatura a las 05  
T06: Temperatura a las 06  
T07: Temperatura a las 07  
T08: Temperatura a las 08  
T09: Temperatura a las 09  
T10: Temperatura a las 10  
T11: Temperatura a las 11  
T12: Temperatura a las 12  
T13: Temperatura a las 13  
T14: Temperatura a las 14  
T15: Temperatura a las 15  
T16: Temperatura a las 16  
T17: Temperatura a las 17  
T18: Temperatura a las 18  
T19: Temperatura a las 19  
T20: Temperatura a las 20  
T21: Temperatura a las 21  
T22: Temperatura a las 22  
T23: Temperatura a las 23  
MAX: Temperatura máxima  
HTMAX: Hora de la temperatura máxima  
MIN: Temperatura mínima  
HTMIN: Hora de la temperatura mínima  
  
Unidades y valores especiales:  
Temperaturas en décimas de grado centígrado  
  
Hora de la temperatura máxima/mínima en horas y minutos  
Valores especiales de hora de la temperatura máxima/mínima:  
9999: La temperatura máxima/mínima se repite varias veces en el día

Ilustración 1: Ejemplo de nota explicativa de los datos de temperatura.

Para poder comprender la cantidad de datos contenidos en la base de datos, se presentan las dimensiones originales de los archivos Excel contenidos en ella en la siguiente tabla:

Tabla 1: Dimensiones de los ficheros proporcionados por AEMET.

FENÓMENO METEOROLÓGICO	TAMAÑO EXCEL AEMET (filas x columnas)
Humedad	3653 x 37
Meteoros	121 x 52
Nubosidad	3653 x 18
Precipitación	3653 x 35
Radiación	1900 x 26
Temperatura	3653 x 37
Viento	3652 x 60

En la siguiente ilustración se muestra un ejemplo de cómo se muestran en la hoja Excel los datos correspondientes a la temperatura. Debido al gran tamaño de la hoja Excel, la información se muestra dividida en dos.

A	B	C	D	E	F	G	H	I	J	K	L	M	
1	INDICATIVO	AÑO	MES	DIA	NOMBRE	ALTITUD	NOM_PROV	LONGITUD	LATITUD	T00	T01	T02	T03
2	C429I	2003	1	1	REINA SOFIA (AEROP.TENERIFE SUR)	64	SANTA CRUZ DE TENERIFE	1634142	280234	220	206	207	205
3	C429I	2003	1	2	REINA SOFIA (AEROP.TENERIFE SUR)	64	SANTA CRUZ DE TENERIFE	1634142	280234	214	204	202	200
4	C429I	2003	1	3	REINA SOFIA (AEROP.TENERIFE SUR)	64	SANTA CRUZ DE TENERIFE	1634142	280234	216	162	159	163
5	C429I	2003	1	4	REINA SOFIA (AEROP.TENERIFE SUR)	64	SANTA CRUZ DE TENERIFE	1634142	280234	207	207	206	206
6	C429I	2003	1	5	REINA SOFIA (AEROP.TENERIFE SUR)	64	SANTA CRUZ DE TENERIFE	1634142	280234	219	219	213	211

N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	AE	AF	AG	AH	AI	AJ	AK
T04	T05	T06	T07	T08	T09	T10	T11	T12	T13	T14	T15	T16	T17	T18	T19	T20	T21	T22	T23	MAX	HTMAX	MIN	HTMIN
203	201	170	196	204	210	241	240	250	250	251	251	250	247	241	229	228	217	214	214	253	9999	144	630
200	198	202	197	180	211	240	252	256	262	161	261	259	254	247	230	226	176	175	175	262	1300	138	9999
149	154	204	213	163	231	199	214	267	277	226	274	222	215	252	220	228	224	224	226	277	1300	143	410
204	207	208	201	199	221	247	262	261	264	264	267	262	259	246	234	226	225	224	223	268	1550	186	820
208	212	209	208	214	226	250	256	264	264	252	263	255	259	256	241	238	240	237	232	270	1220	204	9999

Ilustración 2: Ejemplo de datos contenidos en base de datos original.

En cuanto a las unidades empleadas en la base de datos son las que se presentan en la tabla siguiente:

Tabla 2: Unidades en que se presentan los datos de la AEMET.

PARÁMETRO	UNIDAD EN EXCEL AEMET
Humedad	Humedad relativa en %
Meteoros	Diversas unidades según fenómeno
Nubosidad	Nubosidad total y total de nubes bajas en octavos de cielo
Precipitación	Décimas de mm
Radiación	Decenas de kilojulio por metro cuadrado (kJ/m <sup>2</sup> )
Temperatura	Décimas de grado centígrado (°C)
Viento	Kilómetro por hora (km/h)

Esta es la base de datos que se ha utilizado en la redacción de los artículos 1 y 2 que se presentan en esta Tesis Doctoral por Compendio de Publicaciones.

En el artículo 3 se hace uso de una base de datos obtenida de la localidad de Turrialba, en las faldas del Volcán de Turrialba en la República de Costa Rica. Esta zona se caracteriza por presentar unas condiciones meteorológicas claramente diferenciadas, ya que posee una estación seca que va desde abril hasta octubre y una lluviosa desde noviembre hasta marzo.

Es en el artículo 3 donde se emplea esta base de datos que se explica brevemente, ya que se utiliza solamente para testear el sistema predictor en otras localizaciones. Está compuesta por datos desde julio de 2007 a mayo de 2010. La frecuencia con la que se muestran los datos es cada 30 minutos y presenta datos meteorológicos relativos a temperatura del aire, temperatura del suelo, humectación de hoja, radiación solar, energía solar, presión atmosférica, velocidad del viento, dirección del viento, sensación térmica, recorrido del viento, lluvia, intensidad máxima de lluvia, humedad y punto de rocío. Si bien carece de información relativa a las unidades empleadas en algunas las magnitudes, sí se dispone de las relativas a temperatura (°C) y radiación solar (vatio por metro cuadrado, w/m<sup>2</sup>). Presenta también el inconveniente de que hay ocasiones en las que se carece de datos por un periodo que varía, pudiendo ser días, semanas o meses.

Por estos motivos esta base de datos se utilizará para realizar test en zonas lejanas.

El sistema de clasificación empleado en los artículos de que consta esta Tesis Doctoral es la ANN. Como pequeño apunte de las mismas se destaca que una ANN es un método de clasificación supervisado [Haykin, 1999]. Está caracterizada por la capacidad de clasificación mediante aprendizaje que posee, similar a la del cerebro humano. Esto aporta al sistema una serie de ventajas frente a los sistemas computacionales convencionales, como pueden ser:

- Aprendizaje adaptativo.
- Auto-organización.
- Robustez y tolerancia a fallos.
- Fácil inserción en la tecnología existente.
- Capacidad de trabajo en tiempo real.

A lo largo de las diversas fases de esta Tesis Doctoral también se ha investigado con otros sistemas de clasificación, como son los árboles de decisión, ajuste de modelos lineales, SVR y SVM.

Una vez se ha caracterizado la base de datos a utilizar, en la mayoría de los artículos presentados en este compendio de publicaciones, e introducido el sistema de clasificación, se procede a explicar la metodología seguida en esta Tesis Doctoral.

Partiendo de la base de datos de la AEMET, en la que los fenómenos meteorológicos se presentan de manera conjunta para ambas estaciones, y para todos los años de la misma (2003 a 2007), el primer paso a realizar es un preprocesado de los datos.

Este preprocesado consiste en primer lugar en obtener de manera independiente los datos para cada estación, separándolos en dos ficheros nuevos e independientes. Una vez obtenidos se procede a eliminar de ellos aquellos días en que se produzca alguna falta de datos debida a averías o mantenimientos de la estación meteorológica. Esta tarea se realizó de manera manual al inicio ya que es necesario

controlar la correcta separación de datos. Una vez se ha realizado, el número de muestras por estación (GC y TF) y por año se muestra en la siguiente tabla.

Tabla 3: Número de muestras por estación y año.

AÑO	GC		TF	
	CON RADIACIÓN	SIN RADIACIÓN	CON RADIACIÓN	SIN RADIACIÓN
2003	-----	8755	1344	8323
2004	4064	8731	2960	7819
2005	1296	8755	3104	8059
2006	1952	8611	5424	8131
2007	3232	8587	5568	8419

El motivo de la existencia de dos valores numéricos diferentes al incluir o no el fenómeno de radiación, es que éste no presenta datos de manera continua a lo largo de todo el tiempo de captura de datos por parte de las estaciones.

Hecho esto, se adaptan los datos a la correcta forma en que deben ser introducidos a cada uno de los diversos sistemas clasificadores encargados de realizar la predicción, que se han utilizado en esta Tesis Doctoral, trabajando en todos los casos bajo entorno Matlab.

Una vez ya se dispone de los datos correctamente etiquetados y parametrizados, se procede a introducirlos en los sistemas clasificadores que serán los que obtengan mediante la implementación de sus algoritmos, la predicción de la variable meteorológica de interés. En el caso de los artículos incluidos en esta Tesis Doctoral por Compendio de Publicaciones, el sistema de clasificación empleado es la ANN.

La ANN será utilizada de dos formas distintas:

1. **Modo de entrenamiento:** En esta fase se creará el modelo a utilizar en la fase de test, ya que por las características de la ANN al ser un sistema de clasificación supervisado, ésta debe ser previamente entrenada. Durante la creación del modelo se van comprobando las diversas configuraciones

posibles en cuanto al número de neuronas de la capa oculta y salida, logrando así la adaptación de los errores a la salida deseada.

2. **Modo de test o clasificación:** A partir del modelo creado en la etapa anterior, la ANN ya es capaz de obtener predicciones de salida deseadas.

La configuración empleada como estándar en los mismos es la formada por 24 neuronas en la capa oculta y 1 neurona en la capa de salida, a esta configuración se llegó tras realizar multitud de pruebas y ensayos a fin de obtener una predicción con el menor error posible a la salida. Pero tal como se observa, en el artículo 3 se realizan test con variedad de configuraciones en cuanto a configuración de la ANN y tamaño de la ventana deslizante.

En este punto se hace necesario explicar el concepto de *ventana deslizante*, el cual también posee una gran importancia a la hora de introducir los datos en la ANN, ya que, de hecho, es este el parámetro que indica la cantidad de datos necesarios para obtener la predicción. Esta ventana deslizante, se desplaza por todo el vector de datos de entrada disponibles e irá obteniendo a la salida de la ANN el valor objetivo que se desea obtener. Ese valor objetivo será el primer valor que se introduce en la ventana deslizante una vez ésta se desplace nuevamente. La siguiente ilustración muestra el concepto de ventana deslizante.

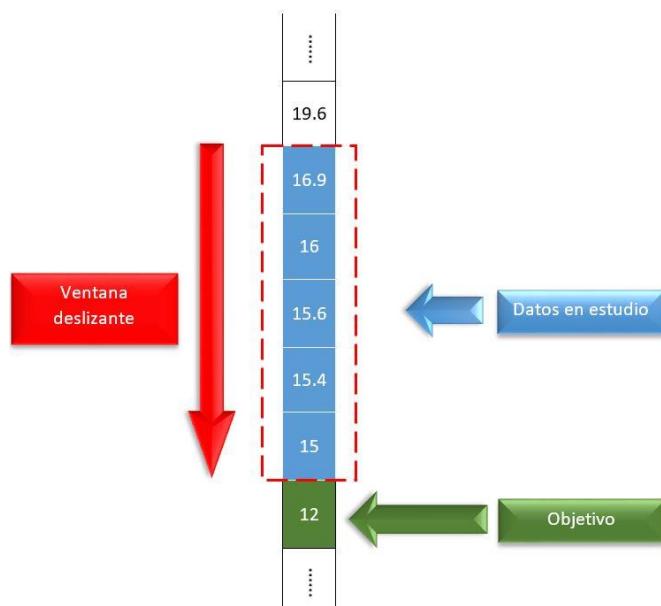


Ilustración 3: Ventana deslizante.

Donde el tamaño de la ventana deslizante (marcado en líneas discontinuas en color rojo) es de 5 muestras que forman los datos en estudio (marcados en azul) y se pretende obtener la predicción del valor objetivo (marcado en color verde).

Una vez ya se ha obtenido el modelo de predicción, se comienza el modo de test.

Es éste sin duda una de los puntos fuertes de este modelo predictivo, ya que mientras la gran mayoría, por no decir todos, de los estudios analizados dedican la mayor parte de las muestras de que disponen a la fase de entrenamiento, dejando una parte pequeña de las mismas a la fase de test, este modelo predictivo hace diametralmente lo opuesto. Dedicando solo el 20% de las muestras a la fase de entrenamiento y el 80% restante a la fase de test.

Para ello, de los 5 años de muestras de las que dispone la base de datos de la AEMET, se emplea para entrenar el modelo el año 2006, el motivo es que el número de muestras de que dispone este año está próximo a la media de muestras de los restantes años. Testeando el modelo con los años 2003, 2004, 2005 y 2007.

También, y a la vista de las unidades en que se ofrecían los datos de la AEMET, se opta por cambiarlas a lo que se da en llamar *unidades más precisas* entendiendo como tales las mostradas en la tabla siguiente:

Tabla 4: Unidades de los datos utilizados en los experimentos.

FENÓMENO METEOROLÓGICO	UNIDADES DE LOS DATOS UTILIZADOS	
	Datos de AEMET	Unidades más precisas y Fusión de fenómenos
Temperatura	Décimas de °C	°C
Velocidad del viento	Kilómetros por hora (km/h)	Metros por segundo (m/s)
Radiación solar	Decenas de kilojulios por metro cuadrado (kJ/m <sup>2</sup> )	Kilovatios hora por metro cuadrado (kWh/m <sup>2</sup> )

En los experimentos realizados cuando se trabaja con varios fenómenos meteorológicos juntos para obtener la predicción de unos de ellos, se trabaja con unidades más precisas ya que se obtienen mejores resultados.

En los artículos presentados en esta Tesis Doctoral por Compendio de Publicaciones, se pretenden realizar experimentos que permitan dar respuesta a la hipótesis planteada en el apartado anterior. La forma en que se validan los resultados obtenidos en las predicciones realizadas en estos artículos es mediante la comparación del valor obtenido con el valor real que ofrece la estación meteorológica en la zona bajo estudio.

Para intentar dar respuesta a la hipótesis planteada se harán experimentos en diferentes localizaciones geográficas, obteniendo predicciones de diferentes variables meteorológicas, con diferente número de muestras de entrenamiento y test, sin utilizar ningún aporte de datos extra a los ofrecidos por la estación meteorológica, con diferentes frecuencias de muestreo de la estación, tal y como se muestra en las secciones de materiales y métodos (artículos 1 y 3) o metodología experimental (artículo 2) y en la sección de resultados de los diferentes artículos publicados. Con ello, se logrará caracterizar climáticamente la zona y se tendrá una herramienta que permita mejorar la eficiencia en los procesos de generación energética.

#### Unidad temática de la Tesis Doctoral por Compendio de Publicaciones

Una vez se ha establecido el marco conceptual en el que se encuadra esta Tesis Doctoral, el objetivo e hipótesis que se pretenden resolver, se presentan seguidamente las consideraciones relativas a la unidad temática de la misma.

En todas las publicaciones se realizan predicciones de variables meteorológicas aplicando en todas y cada una de ellas diferentes variaciones del algoritmo del banco de pruebas que implementa el modelo predictivo. En todas ellas el sistema de clasificación empleado es la ANN, en los artículos 1 y 2 se conserva la configuración de 24 neuronas en la capa oculta y 1 en la capa de salida con un tamaño de ventana deslizante de 5 muestras. En el artículo 3 se varían estas características para comprobar más variantes de la misma.

En el artículo 1 se realiza mediante una normalización por décadas de los valores de las variables meteorológicas en estudio. Se realiza esta normalización previamente a la realización de los experimentos y se vuelve a desnormalizar una vez obtenidos los resultados. En este caso, se realiza la predicción de la velocidad del viento, aplicada a la generación de energía eólica.

En el artículo 2 se realiza el método del más votado. Este método consiste en la repetición del experimento en su totalidad (fases de entrenamiento y test) un número de veces determinado. Como consecuencia de esta repetición el MAE que se obtiene se va reduciendo hasta llegar un momento en que se mantiene constante. En este caso, se obtiene una predicción de temperatura.

En el artículo 3 se realiza el método de *Score Fusion*, consistente en utilizar varias ANN en paralelo y con los valores de salida obtenidos de cada una de ellas realizar una media que es el valor final obtenido de la predicción. Obteniendo como resultado final una predicción de temperatura.

Si bien los artículos 1 y 2 hacen uso de la base de datos AEMET, el artículo 3 hace uso de la base de datos de Costa Rica a la que se hacía referencia anteriormente. El motivo no es más que el de comprobar la aplicabilidad del modelo en unas condiciones climáticas diferentes a las conocidas en Canarias y a miles de kilómetros de distancia.

Todas las variables meteorológicas pueden caracterizarse como impulsos o señales de entrada a un sistema, por lo que son fácilmente abordables por los sistemas de clasificación estudiados a lo largo de esta Investigación y que han sido comentados anteriormente.

Para tratar de explicar mejor el Modelo Predictivo se presenta en la siguiente ilustración el diagrama de bloques general que lo forma.



Ilustración 4: Diagrama de bloques del Modelo Predictivo.

Partiendo de la Base de Datos formada por los valores numéricos de las diversas variables meteorológicas captadas por las estaciones de que dispone la AEMET por el territorio español, se realiza un preprocessado de las mismas. Hecho esto, se introducen en el algoritmo predictivo diseñado e implementado, sometiendo los datos a un banco de pruebas. Como resultado, se obtiene una predicción precisa de aquella variable meteorológica que se desea estudiar.

Se demostrará la efectividad del Modelo Predictivo para obtener valores muy próximos a los reales en cada variable meteorológica a estudiar (temperatura, radiación solar y velocidad del viento). Para ello hay que buscar la combinación de variables meteorológicas que ofrecen un mejor resultado según la variable en estudio.

## Presentación de los trabajos publicados

Al ser esta una Tesis Doctoral por Compendio de Publicaciones, en este apartado se presentan (de la más reciente a la más antigua) las referencias de los tres artículos científicos que la componen. Se indica además el IF, posición en el ranking y cuartil según el JCR 2017 al que pertenece cada uno de ellos. También se indica la página en la que se encuentra cada uno de ellos dentro de esta Tesis Doctoral.

1. **Hernández-Travieso, J.G.**, Travieso-González, C.M., Alonso-Hernández, J.B., Ravelo-García, A.G., Canino-Rodríguez, J.M. "Modeling a robust wind-speed forecasting to apply to wind-energy production." Neural

Computing & Applications 2018, pp. 1-15.

<https://doi.org/10.1007/s00521-018-3619-6>

JCR 2017: IF: 4.213, 15/132, Q1 (Computer Science, Artificial Intelligence)

Página: 57

La ilustración siguiente representa el diagrama de bloques para el artículo 1.



Ilustración 5: Diagrama de bloques del Modelo Predictivo para el artículo *Modeling a robust wind-speed forecasting to apply to wind-energy production*

2. Hernández-Travieso, J.G., Ravelo-García, A.G., Alonso-Hernández, J.B., Travieso-González, C.M. “Neural networks fusion for temperature forecasting.” Neural Computing & Applications 2018, S.I.: Advances in Bio-Inspired Intelligent Systems, pp. 1-12.

<https://doi.org/10.1007/s00521-018-3450-0>

JCR 2017: IF: 4.213, 15/132, Q1 (Computer Science, Artificial Intelligence)

Página: 75

La ilustración siguiente representa el diagrama de bloques para el artículo 2.

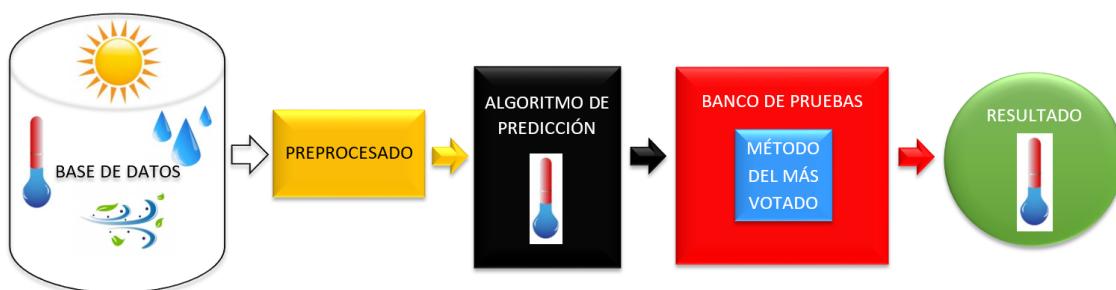


Ilustración 6: Diagrama de bloques del Modelo Predictivo para el artículo *Neural networks fusion for temperature forecasting*

3. Hernández-Travieso, J.G., Herrera-Jiménez, A.L., Travieso-González, C.M., Morgado-Dias, F., Alonso-Hernández, J. B., Ravelo-García, A.G. “Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development.” Sustainability 2017, 9, 193  
<http://www.mdpi.com/2071-1050/9/2/193>

JCR 2017: IF: 2.075, 21/33, Q3 (Green & Sustainable Science & Technology), 120/241, Q3 (Environmental Science)

Página: 89

La ilustración siguiente representa el diagrama de bloques para el artículo 3.

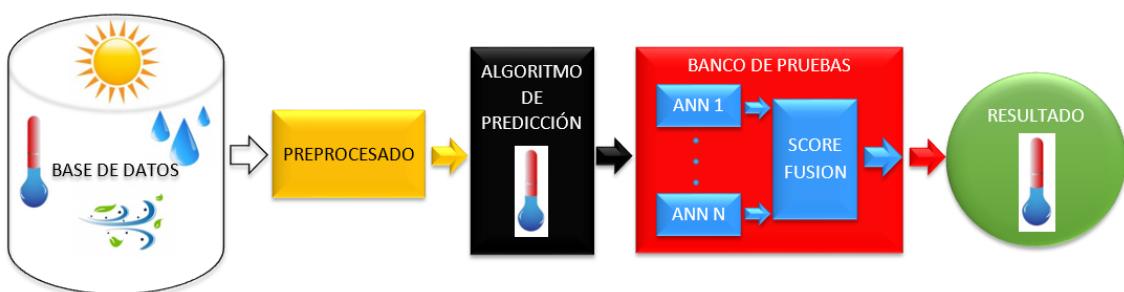


Ilustración 7: Diagrama de bloques del Modelo Predictivo para el artículo *Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development*.

El doctorando es el primer autor de todas y cada una de ellas.

Tal como se observa en el título de las mismas, en todas ellas se realizan predicciones de magnitudes meteorológicas, aplicando el mismo método de clasificación, conservando la unidad temática de la Tesis Doctoral.

## Trabajos publicados

A continuación se presentan los tres trabajos publicados para la obtención del Compendio de Publicaciones. La presentación se hará del trabajo más reciente al más antiguo. En primer lugar se muestra un resumen de cada publicación en español al estar todos los artículos publicados en inglés. Y a continuación la copia de cada publicación, indicando título, revista, JCR 2017 (IF, ranking, cuartil y categoría) y fecha de publicación online de cada uno de ellos acompañado de la URL correspondiente.



Resumen Artículo “Modeling a robust wind-speed forecasting to apply to wind-energy production”

### ***Resumen***

Para obtener energías renovables, es importante conocer con antelación una estimación de las condiciones meteorológicas. En el caso de la energía eólica, otro factor importante e la determinación del momento adecuado para detener la turbina en caso de vientos fuertes para prevenir daños. Esta investigación presenta una herramienta, no solo para incrementar la generación de energías limpias utilizando el viento, reduciendo las emisiones de CO<sub>2</sub>, sino también para prevenir las averías en las turbinas, lo cual es especialmente interesante para los fabricantes.

Utilizando ANN y datos de las estaciones meteorológicas ubicadas en los aeropuertos de Gran Canaria y Tenerife Sur (ambos en las Islas Canarias, España), se presenta una sistema predictor robusto capaz de determinar la velocidad del viento con un MAE de 0.29 m/s.

### ***Introducción***

En un mundo en el que las fuentes de energía predominantes provienen de combustibles fósiles y los países tratan de liderar estrategias que reduzcan las emisiones de CO<sub>2</sub>, la Unión Europea desarrolló el 7º Programa de Acción Medioambiental con el fin de reducir emisiones e incrementar la generación de energías limpias en 2020. En diciembre de 2015 se celebró en París la 21<sup>a</sup> edición de Conferencia de las Partes de la Convención Marco de Naciones Unidas sobre el Cambio Climático (COP21), en ella sus participantes acordaron reducir el incremento global de temperatura en menos de 2 °C y el objetivo de alcanzar el 100% de energías renovables en la lucha contra el cambio climático.

Estos son tan solo dos ejemplos de la importancia de utilizar energías renovables, no solo por beneficios económicos, sino también medioambientales.

La isla canaria de El Hierro utiliza desde el 27 de junio de 2014 una central hidroeólica que es capaz de generar el 100% de la energía utilizada en la isla, tan solo con fuentes renovables. Gracias a sus especiales condiciones meteorológicas y orográficas es posible conseguir este objetivo. Gracias a esta central, se ha logrado ahorrar 1.8 millones de euros al año y se ha evitado emisión de 18700 toneladas de dióxido de azufre y 400 toneladas de óxido de nitrógeno al año.

La contribución de esta investigación radica en dos ejes principales. Primero, mejorando la generación de energía eólica, lo cual es especialmente interesante en las Islas Canarias, con unas condiciones inmejorables que hacen que fabricantes como Siemens-Gamesa estén probando en Arinaga el mayor aerogenerador *off-shore* de España y uno de los mayores del mundo. Segundo, ayudando a la reducción de costes en los procesos de generación energética, reduciendo las emisiones de CO<sub>2</sub> gracias a precisas predicciones climatológicas, y, por lo tanto, logrando edificios más eficientes desde el punto de vista del consumo energético. Además, puede usarse como producto de valor añadido para compañías turísticas a la hora de organizar actividades en el momento adecuado.

Por medio del diseño e implementación del modelo para la velocidad del viento, esta contribución puede ser posible.

Las estaciones meteorológicas utilizadas en este estudio están localizadas en el Aeropuerto de Gran Canaria y el Aeropuerto de Tenerife Sur y están controladas por la AEMET. Estas estaciones están situadas cerca de lugares donde el viento tiene gran importancia como son Pozo Izquierdo en Gran Canaria (a menos de 12 km de la estación) y El Médano en Tenerife (a menos de 5km de la estación), en ambos lugares se desarrolla el Campeonato del Mundo de Windsurf de la PWA (*Professional Windsurfers Association World Tour*). Además, la región sureste de ambas islas tiene gran importancia en la generación de energía eólica y poseen las mismas condiciones climáticas, en relación a las condiciones del terreno, como la ubicación de ambas estaciones en los aeropuertos.

El diagrama de bloques que forma el modelo consta de dos modos claramente diferenciados, como clasificador supervisado que es. Un modo de entrenamiento en el

que se utilizan los datos de entrenamiento del sistema, y un modo de test en el que se utilizan los datos de test. La parte inicial del modelo debe ser la misma para ambos modos. El modelo se genera en el modo de entrenamiento y posteriormente es utilizado en el modo de test con muestras ciegas para obtener el modelado de la velocidad del viento.

La predicción puede utilizarse en una turbina para, dependiendo de sus características técnicas, poder indicar la energía que puede producir.

### ***Materiales y métodos***

La base de datos utilizada proviene de la AEMET y se obtiene en hojas en formato .xls. Una hoja por fenómeno meteorológico contenido los datos de ambas estaciones por un periodo de 5 años, de 2003 a 2007 ambos inclusive. La frecuencia de muestreo es de 60 minutos.

Para introducir correctamente los datos en la ANN bajo entorno Matlab, se hacen necesarios seguir los pasos siguientes:

- a) Separar los datos de las diferentes estaciones: debido a que éstos vienen en una sola hoja Excel.
- b) Revisar los datos: ya que en ocasiones hay ausencia de datos por diversos motivos, averías de los sensores, labores de mantenimiento o cambios en la frecuencia de recogida de muestras para algún parámetro. Cuando esta ausencia de datos es detectada, el día completo se elimina para no introducir datos falsos en la ANN.
- c) Unión de datos para introducirlos en Matlab: éste es un paso significativo en la metodología, ya que en primer lugar es necesario detectar los fenómenos que ofrecen más información de acuerdo a la ausencia de datos, la existencia de datos a lo largo de todo el periodo de tiempo de estudio. Por estos motivos, se desechan los datos relativos a:
  - a. Humedad: solo presenta datos de manera continua en los dos últimos años de estudio.

- b. Meteoros: para este estudio, no son una fuente significativa de información.
- c. Nubosidad: no presenta datos de manera continua durante el día.
- d. Radiación solar: no presenta datos de manera continua durante el día.

En segundo lugar, los datos ofrecidos por la AEMET son adaptados a unidades más precisas y se añaden al fichero resultante que contiene los datos de precipitación (en décimas de mm) de AEMET, temperatura (en décimas de °C) de AEMET, velocidad del viento (en km/h) de AEMET, temperatura en °C, precipitación en mm, y velocidad del viento en m/s.

Hecho esto se introduce los datos en la ANN bajo entorno Matlab. Habiendo logrado un total de 84190 muestras que permiten realizar el estudio en dos localizaciones geográficas diferentes GC y TF.

En esta investigación se utiliza ANN con perceptrón multicapa *feed forward* y algoritmo BP como sistema de predicción, con 24 neuronas en la capa oculta y 1 neurona en la capa de salida. La inicialización de pesos de los valores de la ANN es aleatoria. En base a métodos heurísticos, se escogió esta configuración de la ANN para obtener resultados con gran precisión.

La ventana deslizante que se utiliza en esta investigación está formada por un número de muestras que llevan a un valor de predicción futura, el valor de velocidad del viento para la hora siguiente y que debe ser muy próximo al valor real que se obtendrá en la estación. El tamaño de ventana deslizante utilizado es de 5 muestras de estudio (correspondiente a cinco horas anteriores) en cada serie de datos. Obteniendo el valor de velocidad del viento de la hora siguiente. Hecho esto, la ventana se desplaza una muestra, y ese valor objetivo (el real) se introduce formando una nueva ventana y así sucesivamente.

Para obtener la predicción se siguen dos caminos. En el primero de ellos se utilizan los datos ofrecidos por las estaciones meteorológicas, con las consideraciones explicadas anteriormente. En el segundo, se realiza una normalización por décadas (dividiendo por 10, 20 o 100), logrando reducir la dispersión de los valores de entrada lo

que conlleva a reducir el error a la salida de la ANN ya que ésta puede modificar mejor los valores de los pesos de los datos de entrada.

Los experimentos a realizar serán los siguientes:

- a) Usando datos normalizados y sin normalizar de AEMET.
- b) Usando datos normalizados y sin normalizar de AEMET con unidades más precisas.
- c) Usando diferentes fenómenos unidos ( fusión de datos normalizados y sin normalizar). En este caso los datos a utilizar serán los correspondientes a aquéllos con unidades más precisas según los resultados obtenidos en a) y b).

En todos los casos, los valores utilizados para obtener la predicción son valores pasados de los fenómenos en estudio.

Durante la investigación se han realizado pruebas con varias combinaciones de fenómenos para obtener la mejor predicción en función del fenómeno bajo estudio. Para entrenar la ANN se utiliza el año 2006 debido a que el número de muestras que presenta este año es próximo a la media de muestras de los años en estudio, testeando la ANN con los años restantes. De acuerdo a los resultados, y siempre basado en métodos heurísticos, se verifica la mejor opción para obtener la mayor precisión en la predicción de la velocidad del viento.

## **Resultados**

Los resultados muestran los valores obtenidos a lo largo de todo el año bajo estudio, no el mejor valor puntual obtenido a lo largo del mismo. Se presentan los parámetros estadísticos de mínimo, máximo, MAE, desviación estándar y error cuadrático medio para las estaciones de GC y TF entre el valor real medido por la estación y el valor de la predicción obtenido por la ANN. El estadístico que marcará la bondad del sistema será el MAE para poder compararlo con los estudios existentes. También se presenta el tiempo de entrenamiento y el de test por muestra en

milisegundos. Independientemente de los datos, las unidades utilizadas para presentar los resultados son siempre las unidades más precisas.

En el caso de los experimentos del tipo a) y utilizando datos sin normalizar el mejor resultado se obtiene en la estación de GC el año 2003 con un MAE de 0.89 m/s. Cuando los datos son normalizados por 100 en la estación de GC en el año 2003 se obtiene un MAE de 1.15 m/s.

En el caso de los experimentos del tipo b) y utilizando datos sin normalizar el mejor resultado se obtiene en la estación de GC el año 2003 con un MAE de 0.85 m/s. Cuando los datos son normalizados por 100 en la estación de GC en el año 2003 se obtiene un MAE de 0.29 m/s.

En el caso de los experimentos del tipo c) y utilizando datos sin normalizar de velocidad del viento y temperatura, el mejor resultado se obtiene en la estación de GC el año 2003 con un MAE de 0.84 m/s. Cuando los datos de velocidad del viento y temperatura son normalizados por 100 en la estación de GC en el año 2003 se obtiene un MAE de 0.44 m/s.

### ***Discusión***

En términos de generación de energía es posible establecer una relación entre velocidad del viento y producción de energía utilizando la curva de carga del aerogenerador.

Para el caso particular del Gamesa G52-850 Kw, la pendiente de la curva de carga indica que una variación de 1 m/s corresponde con 100 kW de energía generada. De acuerdo a esto, esta investigación alcanza un error de 0.29 m/s correspondiente a 29 kW o un 3.43% de desviación.

Comparativamente con los estudios previos, este sistema supone una mejora y abre la vía de más investigaciones.

## **Conclusión**

Una vez el estudio se ha llevado a cabo, se ha comprobado que el fenómeno que ofrece mayor información para obtener una predicción de velocidad del viento es la velocidad del viento. Por otro lado, la precipitación no provee información relevante para una correcta predicción de velocidad del viento.

El resultado se presenta como el valor medio de todo el año bajo estudio, no es el mejor resultado puntual obtenido en el mismo, para una localización específica.

El uso de unidades más precisas ofrece mejores resultados que los datos ofrecidos directamente por la AEMET 0.29 frente a 0.86 m/s respectivamente. Los tiempos de predicción son muy cortos.

La gran fortaleza del modelo es que no necesita poseer diversos tipos de datos para ofrecer una predicción precisa, esto quiere decir que, aunque la humedad, nubosidad y radiación solar puedan ser variables importantes, el sistema es capaz de conseguir predicciones muy precisas sin utilizarlas.

Otra de las fortalezas del sistema es la versatilidad, alcanzando gran precisión en la predicción de diversas variables meteorológicas en diferentes localizaciones geográficas, ayudando a generar energías renovables y reduciendo las emisiones de CO<sub>2</sub>. La predicción puede ser utilizada en un aerogenerador para, en función de sus características técnicas, poder saber la cantidad de energía a generar.

Finalmente, otra ventaja es el periodo de muestreo ya que independientemente de que se compare con otros trabajos con periodos inferiores, los resultados obtenidos son mejores. Además, el sistema puede ser una herramienta interesante para pequeños productores de energía como casas aisladas o empresas que quieren hacer utilizar energías renovables en lugar de o además de aquellas obtenidas con combustibles fósiles.



## Resumen Artículo “Neural networks fusion for temperature forecasting”

### **Resumen**

Las condiciones meteorológicas tienen una relación directa con el consumo energético, las actividades turísticas y las tareas agrícolas. Mediante la fusión de ANN, este trabajo presenta un sistema con un método general que permite obtener precisas predicciones de temperatura. El objetivo del mismo es la temperatura, pero el método es fácilmente escalable para su aplicación a cualquier otra variable meteorológica de interés, lo cual es una de las fortalezas del modelo. Esta investigación realiza un modelado de predicciones de temperatura, contribuyendo a la obtención de mejores resultados, con aplicaciones que van desde la generación energética al turismo o agricultura. La base de datos contiene información proporcionada durante 5 años por las estaciones situadas en el Aeropuerto de Gran Canaria y en el Aeropuerto de Tenerife Sur. Los datos se recogen cada hora, lo que significa un total de más de 100000 muestras, lo que da robustez al estudio. Con este método, el mejor resultado en términos de MAE es de 0.41 °C.

### **Introducción**

Este trabajo presenta un nuevo modelo de fusión de ANN para obtener predicciones de temperatura. Utilizando el método del más votado, esta propuesta puede aplicarse en la mejora de la eficiencia de los procesos de generación de energía y para incrementar el uso de energías renovables.

En la actualidad las fuentes derivadas del petróleo o el carbón son las más utilizadas en los procesos de generación energética, contribuyendo al incremento de temperatura y el efecto invernadero.

Además, en España y Portugal, la eficiencia en los procesos de generación con combustibles fósiles en 2013 era solo del 39.20%, frente al 80% de la energía hidráulica, lo cual representa claramente el interés de utilizar energías renovables para obtener mejores eficiencias en los procesos de generación.

Es nuestra tarea enfrentarnos a esa realidad y reconvertirla por medio de la utilización de energías renovables.

En las Islas Canarias, puede observarse un ejemplo de ello en la Isla de El Hierro. En ella se utiliza la caída de agua entre dos depósitos situados a diferentes altitudes para generar energía de manera limpia. Unos aerogeneradores se encargan de generar la energía necesaria para desplazar nuevamente el agua del depósito inferior al superior. Esto brinda la posibilidad de que la isla utilice fuentes limpias para generar la electricidad necesaria para su abastecimiento. Además del beneficio económico que supone el ahorro de 6000 toneladas de diésel, creando un ahorro de 1.8 millones de euros al año, se evita emitir 18700 toneladas de CO<sub>2</sub>, 100 toneladas de dióxido de azufre y 400 toneladas de óxido de nitrógeno, con lo que ello representa de beneficio medioambiental.

En un intento de contribuir en esta área, este trabajo ayuda, por un lado, a incrementar la eficiencia energética en los procesos de generación debido a que una precisa predicción de temperatura ayuda a reducir costes cuando se emplean fuentes de combustible fósiles, reduciendo las emisiones de CO<sub>2</sub> y haciendo más eficientes los edificios. Por otro lado, puede ser un impulso a la generación con fuentes renovables mediante el uso y/o combinación de energía solar y eólica. Permite además que las empresas turísticas puedan realizar sus actividades en el momento adecuado, convirtiéndose en un producto de valor añadido.

Esta contribución puede ser posible gracias al diseño e implementación de fusión de ANN. Los datos meteorológicos empleados se obtienen de las estaciones meteorológicas de que dispone la AEMET tanto en el Aeropuerto de Gran Canaria, como en el Aeropuerto de Tenerife Sur.

### ***Preprocesado***

Es una etapa que requiere tres pasos para la correcta introducción de los datos meteorológicos en el sistema de clasificación utilizado, la ANN.

- a) Separación de datos de diferentes estaciones: debido a que los datos se obtienen en un fichero con formato .xls conteniendo la información de ambas estaciones para cada fenómeno meteorológico. La separación en dos ficheros diferentes, uno para cada estación, permite la realización de dos estudios separadamente, uno para cada estación.
- b) Revisión de datos: eventos como averías, cambios en la rutina de recogida de datos o cualquier acontecimiento que lleve a la ausencia de datos por un periodo de tiempo que puede variar de una o dos horas a incluso un día. En aquellos días en que esta incidencia ocurre, se eliminan los datos por completo, evitando introducir datos erróneos o falsos en el sistema.
- c) Unión de los datos en Matlab: es la última etapa. Una vez los datos se han unido correctamente son introducidos en Matlab. En primer lugar se investiga qué fenómeno meteorológico ofrece mayor información (existencia de mayor cantidad de datos adquiridos durante los 5 años de estudio), en base a ello, se eliminan de la base de datos los siguientes fenómenos:
  - a. Humedad: solo hay datos de los años 2006 y 2007.
  - b. Meteoros: es una variable no significativa en este estudio.
  - c. Nubosidad: los datos no se presentan de manera continua a lo largo del día.

Finalmente, es necesario transformar el fichero .xls en un fichero .txt utilizando Matlab. Este último será el que se introduce en Matlab para lograr la predicción de temperatura en este estudio. También se adaptan los datos ofrecidos por la AEMET a unidades más precisas y se añaden al fichero resultante que contiene los datos de precipitación (en décimas de mm) de AEMET, temperatura (en décimas de °C) de AEMET, velocidad del viento (en km/h) de AEMET, temperatura en °C, precipitación en mm, velocidad del viento en m/s, radiación solar de AEMET (en decenas de kJ/m<sup>2</sup>) y radiación solar (en kWh/ m<sup>2</sup>).

### **Sistema de predicción**

Este trabajo utiliza la ANN como sistema de predicción. Una ANN es una máquina que está diseñada para modelar la forma en la que se comporta el cerebro cuando realiza una tarea o función de interés. Ésta puede implementarse mediante componentes electrónicos o en un ordenador utilizando *software*.

La ANN utilizada en este estudio es un perceptrón multicapa *feed forward* con algoritmo BP, 24 neuronas en la capa oculta y 1 en la capa de salida. El algoritmo BP se utiliza para reducir el error resultante en pos de obtener una mejor predicción de temperatura. Se utiliza la aproximación BP, que está basada en el algoritmo Lavenberg-Marquardt. El algoritmo Lavenberg-Marquardt está diseñado para aproximar el entrenamiento de segundo orden sin necesidad de calcular la matriz hessiana que presenta las segundas derivadas parciales.

La ventana deslizante utilizada en este trabajo consta de cinco muestras de estudio permitiendo la obtención del valor a predecir y que debe ser muy próximo al valor real. A continuación, la ventana se desliza una muestra y el proceso se repite.

### **Metodología experimental**

#### a) Base de datos:

Se utilizan datos recolectados por estaciones dependientes de la AEMET relativos a velocidad del viento, precipitación, humedad, temperatura, radiación solar, nubosidad y meteoros.

El motivo de su utilización es la fiabilidad de la institución, dependiente del Gobierno de España y la localización de las estaciones utilizadas, próximas a zonas donde la generación de energías renovables es posible.

Cada fenómeno meteorológico está contenido en un único fichero .xls con datos de las dos estaciones (GC y TF) juntas para un periodo de 5 años (2003 a 2007 ambos inclusive).

Los datos de temperatura, precipitación, radiación solar y velocidad del viento se recogen cada hora por el sensor específico localizado en la estación. Tal como se explicó anteriormente, una serie de datos no se han incluido en este estudio.

b) Experimentos:

Una vez se ha concluido la etapa de preprocesado, los datos se introducen en entorno Matlab para ser procesados por la ANN. Se harán experimentos con dos combinaciones de datos, una con radiación (incluye temperatura, radiación solar, precipitación y velocidad del viento) y otra sin radiación (incluye temperatura, precipitación y velocidad del viento).

La razón de esta diferenciación en cuanto a los datos a utilizar es debida a la no existencia de datos de radiación durante todo el tiempo de estudio.

Se seguirán dos líneas para conseguir una precisa predicción de temperatura. Por un lado, se obtendrá la predicción de temperatura realizando el experimento una sola vez.

Por otro lado, se utiliza el método del más votado, consistente en la repetición de todo el procesado de datos (entrenamiento y test) para todos los datos involucrados un número específico de veces (100 veces en este caso). Durante este proceso, el MAE se va reduciendo paulatinamente hasta permanecer constante. El resultado final es el fruto de la media aritmética de los resultados obtenidos en cada repetición, a esto es a lo que se llama fusión en este trabajo. Con esto se logra una mejora frente a la realización de los experimentos una sola vez.

Aplicando métodos heurísticos, se introduce la información proveniente de las estaciones, bien en la forma que la proporciona la AEMET, bien utilizando unidades más precisas.

De acuerdo a esto, se realizan los siguientes experimentos:

1) Utilizando datos de la AEMET:

- a. Una vez.
- b. Método del más votado.

- 2) Utilizando unidades más precisas:
  - a. Una vez.
  - b. Método del más votado.
- 3) Utilizando diferentes fenómenos unidos: fusión de datos.
  - a. Una vez.
  - b. Método del más votado.

En todo el estudio, se utilizan los datos pasados de cada fenómeno involucrado en la predicción.

Para obtener la configuración correcta de la ANN en términos de número de repeticiones de entrenamiento y número correcto de neuronas en capa oculta, se aplicaron métodos heurísticos.

El sistema fue entrenado aplicando *Neural Networks Toolbox* de Matlab. De acuerdo al número de muestras contenido, próximo a la media de las de todos los años incluidos en el estudio, el año 2006 se utilizó para entrenar la ANN, testeando la ANN con los demás años restantes.

Este es uno de los puntos fuertes del sistema, ya que solo se emplea el 20% de las muestras en entrenamiento y se prueba con el 80% de las muestras que forman el estudio.

De acuerdo a los resultados obtenidos, se elige la mejor combinación de fenómenos meteorológicos para obtener la predicción.

## **Resultados**

Los resultados muestran los parámetros estadísticos de mínimo, máximo, MAE, desviación estándar y error cuadrático medio para las estaciones de GC y TF entre el valor real medido por la estación y el valor de la predicción obtenido por la ANN. El estadístico que marcará la bondad del sistema será el MAE. También se presenta el tiempo de entrenamiento (tiempo empleado en entrenar el sistema) y el de test por muestra (tiempo en el que se procesa una muestra) en segundos. Independientemente

de los datos, las unidades utilizadas para presentar los resultados son siempre las unidades más precisas.

En el caso de los experimentos 1.a) el mejor resultado se obtuvo en GC utilizando datos de temperatura en el año 2003 con una MAE de 0.44 °C. En el caso 1.b) el mejor resultado se obtuvo en GC también en el año 2003 utilizando datos de temperatura con 0.42 °C, en este caso, el MAE permanece constante desde la repetición número 42.

En el caso de los experimentos 2.a) el mejor resultado se obtuvo en GC utilizando datos de temperatura en el año 2003 con una MAE de 0.42 °C. En el caso 2.b) el mejor resultado se obtuvo en GC también en el año 2003 utilizando datos de temperatura con 0.41 °C, en este caso, el MAE permanece constante desde la repetición número 56.

En el caso de los experimentos 3.a) el mejor resultado se obtuvo en GC utilizando datos de temperatura, precipitación y velocidad del viento en el año 2003 con una MAE de 0.44 °C. En el caso 3.b) el mejor resultado se obtuvo en GC también en el año 2003 utilizando datos de temperatura, precipitación y velocidad del viento con 0.42 °C, en este caso, el MAE permanece constante desde la repetición número 87.

### ***Conclusiones***

Este trabajo demuestra que la técnica nueva del uso de fusión de ANN mediante el método del más votado obtiene mejores resultados que cuando se utiliza una sola ANN, 0.41 °C frente a 0.42 °C.

Respecto a la predicción de temperatura, la precipitación proporciona menor cantidad de información. Por el contrario, si la precipitación se une a la temperatura y a la velocidad del viento para lograr una predicción de temperatura, se obtienen mejores resultados, comprobando de nuevo que la utilización de unidades más precisas ofrece mejores resultados que aquella en la que se utilizan los datos directamente de la AEMET, 0.41 °C frente a 0.42 °C.

En comparación con anteriores estudios, el modelo aquí presentado supera a casi todos en cuanto a precisión del resultado.

Tal como queda comprobado, el sistema es capaz de ofrecer una precisa predicción de temperatura en términos de milisegundos.

La versatilidad es otra de las fortalezas del sistema, ya que es capaz de obtener precisas predicciones de diversos fenómenos meteorológicos en diferentes ubicaciones geográficas, ayudando a la generación de energías renovables y reduciendo las emisiones de CO<sub>2</sub>. Además puede ser una herramienta para pequeños productores de energía como hogares aislados o empresas que deseen utilizar energías renovables en lugar de o además de aquellas de origen fósil.

Resumen Artículo “Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development”

### **Resumen**

El control de la temperatura y su predicción se ha convertido en un desafío de investigación para el conocimiento del planeta y sus efectos en diferentes actividades humanas y esto puede asegurar, en conjunción con la eficiencia energética, un desarrollo sostenible reduciendo las emisiones de CO<sub>2</sub> y el consumo de combustibles. Este trabajo trata de ofrecer una solución práctica a la predicción y control de temperatura, que tradicionalmente ha venido siendo realizada por instituciones especializadas. Para la realización de la estimación de temperatura, se ha utilizado un bloque de *Score Fusion* basado en ANN. La base de datos está compuesta por datos de una estación meteorológica con 20000 valores de temperatura y 10000 valores de diversos fenómenos meteorológicos. Por tanto, se resuelve la complejidad de los modelos tradicionales de pronóstico. Obteniéndose como resultado un sistema práctico que alcanza un error cuadrático medio de 0.136 °C para predicciones a corto plazo y de 5 °C para predicciones a largo plazo.

### **Introducción**

Las sociedades modernas están condicionadas por múltiples factores naturales, como por ejemplo, la climatología. Los cambios climáticos afectan diferentes aspectos de nuestras vidas, no solo a aquellos relacionados directamente con ellos como pueda ser el sector agropecuario, sino también sobre otros más complejos y aparentemente disociados de la climatología como pueda ser la eficiencia energética. Ésta se convierte en un factor importante a la hora de realizar un planeamiento sostenible en el desarrollo urbano.

De hecho, el clima es un factor que afecta a la economía. Es especialmente importante no solo en aquellas áreas basadas en la producción agrícola (como en los países en desarrollo) sino también en otras áreas tecnológicamente desarrolladas y

cuyas economías se basan en otros sectores como puedan ser el turismo o incluso en aquellas que tratan de aproximarse a un desarrollo sostenible a través del uso de energías renovables. La predicción meteorológica es, por tanto, una herramienta a modelar y desarrollar que puede ser comparada con los diferentes procedimientos para cada área específica. En la actualidad hay tres vertientes que abordan este tema: Climatología, actuando como tradición empírica; Física de la Atmósfera como tradición teórica y NWP como tradición moderna. Estos recientes modelos matemáticos luchan en la actualidad por conseguir menores tiempos de respuesta como principal objetivo. Sin embargo, mientras más preciso es el método, mayor cantidad de datos necesita y, por tanto, mayor cantidad de tiempo requiere para obtener la predicción.

Los servicios meteorológicos se basan en el desarrollo de algoritmos tradicionales, pero, de hecho, existen alternativas emergentes enfocadas en el futuro de las predicciones meteorológicas, como ANN con entrenamiento supervisado. La predicción de temperatura a través de series temporales es una técnica importante, en ella se observan valores pasados de diversos fenómenos meteorológicos recogidos y analizados para desarrollar un modelo basado en la relación subyacente entre ellos. Es importante tener en cuenta que la predicción de temperatura es un sistema caótico en el que pequeños errores en las condiciones iniciales de la predicción crecen rápidamente afectando las previsiones.

En esta investigación se presentan 4 contribuciones o innovaciones frente al estado-del-arte. Primero, la utilización de la topología *feedback* para estudiar diferentes configuraciones para determinar cómo es el comportamiento de esta arquitectura en la predicción de temperatura. Segundo, la combinación de diversos fenómenos meteorológicos como estímulo de entrada que afectan directamente los ciclos de temperatura. Tercero, para realizar una evaluación heurística, se introduce una optimización basada en *Score Fusion* para comprobar la mejora en la predicción de esta propuesta. Finalmente, se realiza una normalización de valores de entrada, la cual puede tener un impacto positivo durante la fase de entrenamiento del sistema.

### **Materiales y métodos**

Tras estudiar estudios relacionados con predicciones con series temporales, la topología BP es la elegida para implementar este estudio, obteniendo una mejora al implementar *Score Fusion* frente a los casos en que solo se utiliza ANN. Debido a la adaptabilidad del sistema, la topología BP es la más adecuada para obtener predicciones realizando entrenamiento con series temporales frente a otras topologías o incluso frente a métodos lineales.

La ANN es un paradigma de procesado de información que se basa en el sistema nervioso biológico humano. El elemento central del mismo es la neurona, la cual gracias a multitud de interconexiones de procesamiento permite a la ANN modelar y representar complejas relaciones de entrada y salida.

Para realizar el método propuesto, se utiliza una base de datos recolectados en la localidad de Turrialba (República de Costa Rica), la cual está caracterizada por un clima de contrastes al estar rodeada por un río y en las proximidades del Volcán de Turrialba, que afecta directamente el clima de la zona.

La base de datos se presenta en formato Excel, conteniendo varias variables meteorológicas como temperatura, humedad, presión atmosférica, velocidad del viento, humectación de hoja, radiación solar, etc. El periodo de toma de datos va desde julio de 2007 a septiembre de 2008 con una frecuencia de muestreo de 30 minutos.

En la etapa de preprocesado, se escogen los elementos involucrados en la entrada de fenómenos combinados, estudiando los elementos más influyentes en los ciclos diarios de temperatura. Dependiendo de la limitación de la base de datos se escogen los parámetros de hora de adquisición de datos, humectación de hoja y radiación solar.

Posteriormente se realiza una normalización de los datos de entrada entre (-1, 1) para resolver dos problemas. Primero, la dispersión de datos presente al trabajar con valores con diferentes escalas de medida se ve reducido claramente. Segundo, el rango de valores usados como peso de las neuronas de entrada es cerrado, alcanzando una convergencia mejor y más rápida en la etapa de entrenamiento.

Respecto a la configuración del sistema propuesto, se basa en tres parámetros. En primer lugar, el tamaño de la ventana deslizante que captura información de la base de datos, representando el número de valores pasados necesarios para obtener una predicción de temperatura. En segundo lugar, el número de neuronas en la capa oculta, que define el número de neuronas fijas en la etapa intermedia. En tercer lugar, para estudiar la respuesta del modelo se establecen las diversas configuraciones de los bancos de pruebas.

Esto ofrece dos modos de trabajo claramente diferenciados. En el primero de ellos, está caracterizado por una topología *non-feedback* para alcanzar valores de predicción inmediatos, donde cada ventana deslizante formada por valores reales estima un valor de temperatura. El segundo está caracterizado por una topología *feedback* para obtener predicciones a corto plazo, en la que, a partir de una ventana deslizante, se obtienen de manera continua valores de predicción de temperatura, usando los valores estimados para obtener una nueva predicción.

El último paso del proceso es el de *Score Fusion*, específicamente la técnica de *Adding-Score* se ha introducido para evaluar si es efectiva o no a la hora de mejorar el modelo propuesto. En este caso la arquitectura BP, que otorga valores aleatorios a los valores de los pesos de entrada a la ANN, es la utilizada. Este hecho causa que, dos ANN idénticas en configuración, muestras de entrenamiento y test, den a su salida resultados diferentes debido a la inicialización aleatoria de los pesos. Las respuestas, aun siendo muy similares, no son idénticas. De este modo, el método de optimización es concebido como una estructura neuronal con varias ANN idénticas trabajando en paralelo y a las cuales se les realiza la media aritmética de las salidas.

Creado el modelo, se le estimula de dos formas para obtener una predicción de temperatura, una con datos exclusivamente de temperatura (estímulo simple) y otra combinando varios fenómenos meteorológicos (estímulo combinado).

Se definen cuatro modos de trabajo:

- 1) Modo 1: topología *non-feedback* (predicción inmediata) y estímulo simple.
- 2) Modo 2: topología *non-feedback* (predicción inmediata) y estímulo combinado.

- 3) Modo 3: topología *feedback* (predicción a corto plazo) y estímulo simple.
- 4) Modo 4 y Modo 4v2: topología *feedback* (predicción a corto plazo) y estímulo combinado.

Para los modos 1 y 3 que solo utilizan valores de temperatura, se utilizan 20000 muestras mientras que para los modos 2 y 4 que utilizan varios fenómenos meteorológicos, se emplean 10000 muestras. La diferencia en el número de muestras es debida a la obtención de mejores resultados con ellas. La diferencia entre el Modo 4 y el Modo 4v2 es que en el Modo 4v2 se utiliza también el parámetro de la hora de adquisición de la muestra.

Para evaluar los errores se utilizan dos criterios para ambas topologías. Para la *non-feedback* se utiliza el MAE mientras que para la *feedback* se utiliza el error acumulado, el cual determina la evolución del error absoluto para cada nuevo valor de temperatura. Y que se define como el error absoluto del uso de las muestras estimadas (las obtenidas en la predicción) para estimar las predicciones futuras.

## Resultados

En esta sección se describen los mejores resultados obtenidos en los cuatro modos explicados anteriormente. Para lograrlos se han aplicado diversos bancos de pruebas con diversas configuraciones de la ANN, ventana deslizante, neuronas de capa oculta y muestras de entrenamiento. Además la optimización basada en *Adding-Score* ha sido aplicada a cada resultado óptimo con el fin de reducir el error obtenido.

- 1) Modo 1: en este caso el MAE es de 0.2639 °C y el error cuadrático medio de 0.1659 °C con ventana deslizante de tamaño 4, 12 neuronas en la capa oculta y 3000 muestras de entrenamiento.
- 2) Modo 2: en este caso el MAE es de 0.2294 °C y el error cuadrático medio de 0.1359 °C con ventana deslizante de tamaño 4, 8 neuronas en la capa oculta y 4000 muestras de entrenamiento.
- 3) Modo 3: en este caso, los parámetros de bondad del sistema no son concluyentes y se muestran solo como indicadores de bondad. Para obtener la

mejor configuración de cada modo se han realizado estudios heurísticos. Esto es debido a que el error acumulado no es instantáneo ya que es el resultado del error actual más los anteriores errores obtenidos. Para predicciones a más largo plazo, se hace necesario una ventana deslizante de mayor tamaño. Sin embargo, si este valor es muy alto, la respuesta del sistema puede ser caótica debido a la generación de una convergencia inestable en la fase de entrenamiento. En este modo es importante saber el horizonte temporal en el que se quiere realizar la predicción ya que para períodos de tiempos mayores, la precisión de las primeras muestras obtenidas será inferior que para aquellas con horizontes temporales más cortos. Con estas consideraciones, el MAE es menor a 1.50 °C y el error cuadrático medio está entre los 5.00 y los 5.40 °C con ventana deslizante de tamaño 24, 12 neuronas en la capa oculta y 4000 muestras de entrenamiento.

- 4) Modo 4: en este caso el error introducido por cada fenómeno individualmente y el introducido por la predicción total ofrece resultados caóticos que desaconsejan el uso de este modo para obtener predicciones de temperatura. Para tratar de solucionar esto, surge el Modo 4v2 en el que se introduce el valor de la hora. Sin embargo, no se muestra efectivo para cortos períodos de tiempo, en los que el Modo 3 ofrece menor error, aunque el Modo 4v2 parece volverse un poco más estable que el Modo 3 para horizontes temporales más lejanos. Sin embargo, este modo no se recomienda para obtener una predicción precisa, recomendándose más el Modo 3.
- 5) Prueba de los rangos con signo de Wilcoxon: para comprobar la significancia estadística de los resultados se realiza dicha prueba. En los experimentos, el valor  $p$  está obtenido con las primeras 48 muestras en todos los casos. Tras la realización de la prueba, se observa el buen rendimiento de los modos 1 y 2.

## **Discusión**

Realizado el estudio se observa que un incremento en el número de neuronas ocultas no ofrece mejores resultados. Esto es debido a que si un alto número de neuronas ocultas se define para una configuración de entrada dada, el sistema se vuelve

inestable, no alcanzando el nivel de convergencia requerido durante la fase de entrenamiento.

El incremento aleatorio de muestras de entrenamiento no ofrece salidas más precisas. Esto es debido a que, tras alcanzar el nivel de estabilidad interna de los valores de los pesos de la ANN, el sistema se vuelve, una vez más, inestable si se le siguen ofreciendo estímulos de entrada. El balance solo puede conocerse a través de métodos heurísticos.

El estudio del tiempo de entrenamiento es una cuestión importante, ya que la latencia entre predicciones, especialmente en las de corto plazo, es clave para lograr un sistema más preciso.

Un punto clave es también el número de neuronas ocultas, ya que se presenta como el aspecto más influyente en los costes computacionales ya que el incremento en este valor genera incrementos lineales en la fase de entrenamiento. Sin embargo esto no afecta al tiempo de test por muestra que sigue siendo casi instantáneo.

La optimización *Adding-Score* no ofrece mejoras significativas para los modos con topología *non-feedback*. Sin embargo, para la topología *feedback* contribuye a minimizar los errores introducidos en el sistema con el uso de los valores estimados utilizados como valores de entrada al sistema.

El objetivo del estudio se ha logrado debido a los resultados obtenidos con un error inferior a 0.30 °C (valor  $p= 0.15$ ) para todos los casos de topología *non-feedback* frente a errores de casi 1 °C del estado-del-arte. Para la topología *feedback*, los errores son inferiores a 1.5 °C para predicciones a 24 horas. Del mismo modo, la inclusión de estímulos combinados mejora la precisión de la predicción y se ha presentado un método rectificador frente a entradas que presentan comportamientos irregulares. Además se ha llevado a cabo un estudio riguroso del comportamiento de la arquitectura *feedback* en el campo de las predicciones. Alcanzando resultados favorables en el caso del uso de estimaciones continuas de tiempo. Igualmente, el uso del método *Score Fusion* a estas arquitecturas, ofrece mejor rendimiento que el obtenido de manera

inicial. La normalización de datos de entrada es recomendable como procedimiento para lograr sistemas más rápidos y estables en cuanto a convergencia.

### **Conclusiones**

Este artículo presenta dos líneas de actuación diferentes, la primera basada en modos *non-feedback*, que son capaces de obtener predicciones precisas de temperatura a lo largo del día.

La segunda basada en modos *feedback* que son útiles para predicciones a corto plazo. Estos modos pueden emplearse en áreas sociales, siendo interesante en áreas urbanas y agrícolas, el sector turístico o incluso para servir de herramienta a los servicios de emergencia a la hora de declarar alertas por fenómenos meteorológicos adversos.

Este estudio presenta una mejora frente al estudio anterior que utiliza la misma base de datos y también ANN pero no *Score Fusion*.

Modeling a robust wind-speed forecasting to apply to wind-energy production

**Revista:** Neural Computing and Applications.

**JCR 2017:** IF: 4.213, 15/132, Q1 (Computer Science, Artificial Intelligence).

**Publicación online:** 14 de julio de 2018.

**URL:** <https://link.springer.com/article/10.1007%2Fs00521-018-3619-6>

*Modeling a robust wind-speed forecasting to apply to wind-energy production*

**José Gustavo Hernández-Travieso,  
Carlos M. Travieso-González, Jesús  
B. Alonso-Hernández, José Miguel  
Canino-Rodríguez, et al.**

Neural Computing and Applications  
ISSN 0941-0643  
Neural Comput & Applic  
DOI 10.1007/s00521-018-3619-6

ONLINE FIRST

Neural Computing & Applications

Springer

Neural Computing and Applications  
https://doi.org/10.1007/s00521-018-3619-6

ORIGINAL ARTICLE

CrossMark

Modeling a robust wind-speed forecasting to apply to wind-energy production

José Gustavo Hernández-Travieso<sup>1</sup> • Carlos M. Travieso-González<sup>1</sup> • Jesús B. Alonso-Hernández<sup>1</sup> • José Miguel Canino-Rodríguez<sup>2</sup> • Antonio G. Ravelo-García<sup>3</sup>

Received 19 May 2017 / Accepted: 10 July 2018  
© The Natural Computing Applications Forum 2018

**Abstract**  
To obtain green energy, it is important to know, in advance, an estimation of the weather conditions. In case of wind energy, another important factor is to determine the right moment to stop the turbine in case of strong winds to avoid its damage. This research introduces a tool, not only to increase green energy generation from wind, reducing CO<sub>2</sub> emissions, but also to prevent failures in turbines that is especially interesting for manufacturers. Using Artificial Neural Networks and data from meteorological stations located in Gran Canaria airport and Tenerife Sur airport (both in Canary Islands, Spain), a robust prediction system able to determine wind speed with a mean absolute error of 0.29 in m per second is presented.

**Keywords** Modeling · Wind-speed prediction · Green energy · Artificial neural networks

**1 Introduction**  
In a world where fossil fuels have the primacy on energy generation [1], and countries tried to lead a strategy to reduce CO<sub>2</sub> emissions, European Union developed the Seventh Environment Action Programme to reduce emissions and to increase green energy generation in 2020 [2, 3]. On December 12, 2015, Paris Agreement of the Conference of the Parties (COP21) by their participants committed to reduce global temperature increases in less than 2 °C and the goal of getting 100% renewable energy in the fight against climate change [4, 5].

These are only two examples about the importance of using green energy, not only for economic benefits, but also for environmental conditions.

In Canary Islands (Spain), we can find an example how green energy can reduce the dependency on fossil fuels in the smallest island, El Hierro. Since June 27, 2014, the island of El Hierro (Canary Islands) has been generating 100% of the energetic needs of the island from renewable sources. This could be possible thanks to the specific climate conditions and orography with altitudes of 1500 m with steep mountainsides beaten by the wind permanently. The use of clean energy produces savings of over 1.8 million euros a year and avoids the emissions of 18,700 tonnes of CO<sub>2</sub>, 100 tonnes of sulphur dioxide, and 400 tonnes of nitrogen oxide per year.

Several works have been published in this topic, only three related to the use of Artificial Neural Networks (ANN) are considered in this state of the art.

Using backpropagation neural networks, Xingpei et al. [7] made short-term predictions of wind speed with data

Published online: 14 July 2018  
Springer



# Modeling a robust wind-speed forecasting to apply to wind-energy production

José Gustavo Hernández-Travieso<sup>1</sup>  · Carlos M. Travieso-González<sup>1</sup>  · Jesús B. Alonso-Hernández<sup>1</sup>  · José Miguel Canino-Rodríguez<sup>2</sup>  · Antonio G. Ravelo-García<sup>1</sup> 

Received: 19 May 2017 / Accepted: 10 July 2018  
© The Natural Computing Applications Forum 2018

## Abstract

To obtain green energy, it is important to know, in advance, an estimation of the weather conditions. In case of wind energy, another important factor is to determine the right moment to stop the turbine in case of strong winds to avoid its damage. This research introduces a tool, not only to increase green energy generation from wind, reducing CO<sub>2</sub> emissions, but also to prevent failures in turbines that is especially interesting for manufacturers. Using Artificial Neural Networks and data from meteorological stations located in Gran Canaria airport and Tenerife Sur airport (both in Canary Islands, Spain), a robust prediction system able to determine wind speed with a mean absolute error of 0.29 m per second is presented.

**Keywords** Modeling · Wind-speed prediction · Green energy · Artificial neural networks

## 1 Introduction

In a world where fossil fuels have the primacy on energy generation [1], and countries treated to lead a strategy to reduce CO<sub>2</sub> emissions, European Union developed the Seventh Environment Action Programme to reduce

emissions and to increase green energy generation in 2020 [2, 3]. On December 12, 2015, Paris Agreement of the Climate Summit (COP21), their participants committed to reduce global temperature increases in less than 2 C and the goal of getting 100% renewable energy in the fight against climate change [4, 5].

These are only two examples about the importance of using green energy, not only for economic benefits, but also for environmental conditions.

In Canary Islands (Spain), we can find an example of how green energy can reduce the dependency on fossil fuels in the smallest island, El Hierro. Since June 27, 2014, the island uses a wind-hydro-pumped station [6] to generate 100% of the energetic needs of the island from renewable sources. This could be possible thanks to the specific climate conditions and orography with altitudes of 1500 m with steep mountainsides beaten by the wind permanently. The use of clean energy produces savings of over 1.8 million euros a year and avoids the emissions of 18,700 tonnes of CO<sub>2</sub>, 100 tonnes of sulphur dioxide, and 400 tonnes of nitrogen oxides per year.

Several works have been published in this topic, only those related to the use of Artificial Neural Networks (ANN) are emphasized in this state of the art.

Using backpropagation neural networks, Xingpei et al. [7] made short-term predictions of wind speed with data

---

✉ José Gustavo Hernández-Travieso  
jose.hernandez149@alu.ulpgc.es  
Carlos M. Travieso-González  
carlos.travieso@ulpgc.es  
Jesús B. Alonso-Hernández  
jesus.alonso@ulpgc.es  
José Miguel Canino-Rodríguez  
jose.canino@ulpgc.es  
Antonio G. Ravelo-García  
antonio.ravelo@ulpgc.es

<sup>1</sup> Signal and Communications Department, Institute for Technological Development and Innovation in Communications (IDeTIC), University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, sn, Ed. de Telecommunicación, Pabellón B, Despacho 111, E35017 Las Palmas de Gran Canaria, Spain

<sup>2</sup> Signal and Communications Department, University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, sn, Ed. de Telecommunicación, Pabellón B, E35017 Las Palmas de Gran Canaria, Spain

obtained from wind turbine generator systems of a wind farm in Zhangbei (People's Republic of China).

Zhao et al. [8] applied the algorithm of Support Vector Regression (SVR) and backpropagation ANN to the mean 10-min time series to predict the wind speed in a wind farm.

Working with Auto-regressive Integrated Moving Average (ARIMA), ANN and polynomial curve fitting model for short-term wind-speed prediction and comparing these results, Tarade and Katti [9] obtained an accurate prediction method.

Bhaskar and Singh [10] designed a statistical-based wind-power forecasting without using numerical weather prediction inputs, using adaptive wavelet neural network and feed-forward neural network.

Nan et al. [11] proposed a new method to improve wind speed based on different gray models and genetic neural network models for the use in a wind farm.

Chen et al. [12] investigated a combination of numeric and probabilistic models: a Gaussian process combined with a numerical weather prediction model applied to wind-power forecasting up to 1 day ahead.

Yoshida et al. [13] described a prediction of wind-speed fluctuation by using hierarchical neural network to improve the wind-speed prediction. They achieve a fluctuation prediction accuracy about 59% and wind-speed prediction accuracy about 43% in 2015.

In 2015, Mert et al. [14] used ANN to estimate the energy production of the wind turbine. The study was carried out in Turkey, and they used hourly data from the Turkish State Meteorological Service. They observed that ANN models provide the best performance for weather parameters composed by stepwise multi-linear regression.

Li et al. [15] used a cooperative coevolution genetic algorithm based on backpropagation neural network reaches an MAE of 0.5468 m/s.

In 2016, Filik and Filik [16] proposed a wind-speed prediction using ANN based on multiple local measurements in Eskisehir (Turkey). They study data collected by a sensor in a smart house in Eskisehir, making a forecast for wind speed, achieving an MAE of 0.503 m/s. The study was realized for a determined location in a specific place.

In 2017, Ulkat and Günay [17] used ANN to obtain a prediction of mean monthly wind speed and optimization of wind power in the Aegean Region of Turkey using data extracted from the Turkish Meteorological Data Archive System. They obtained an MAE value of 0.32 m/s for tenfold cross validation.

This work contributes in two main axes: first, improving the generation of green energy based on wind power that is especially interesting in Canary Islands (Spain), where the conditions are outstanding and manufacturers like Gamesa are testing the biggest off-shore turbine of Spain and one of

the biggest of the world in Arinaga ( $27^{\circ}50'43.9''N$   $15^{\circ}23'48.8''W$ ) (Gran Canaria, Spain) [18, 19]; secondly, helping to reduce power generation costs by means of fossil fuels, reducing CO<sub>2</sub> emissions thanks to a precise weather prediction, and thus making buildings more efficient from an energy consumption point of view. In addition, it could be used to stop wind turbines previous to a severe storm [20]. Besides, it could be used as an added-value product for touristic companies allowing it to organize activities in the right moment. By means of the design and implementation of a wind-speed model, using ANN back propagation algorithm, this contribution could be possible.

Meteorological stations used in this work were located in the island of Gran Canaria, at the Gran Canaria Airport (GC) ( $27^{\circ}55'55''N$   $15^{\circ}23'12''W$ ) and in the island of Tenerife, at Tenerife Sur Airport (TF) ( $28^{\circ}02'40''N$   $16^{\circ}34'21''W$ ), and was controlled by the State Meteorological Agency (Agencia Estatal de Meteorología, AEMET). These stations are closer to places where wind speed has great importance like Pozo Izquierdo ( $27^{\circ}49'17.8''N$   $15^{\circ}25'24.4''W$ ) in Gran Canaria (less than 12 km from the station) or El Médano ( $28^{\circ}02'44.1''N$   $16^{\circ}32'01.2''W$ ) in Tenerife (less than 5 km from the station); both places are host villages of the Professional Windsurfers Association (PWA) World Tour [21]. In addition, the south east region of both islands is important in wind-energy generation [22] and has the same conditions, regarding to terrain conditions, as the location of the meteorological stations in both airports.

The blocks that constitute our wind prediction system are shown in Fig. 1. There are two modes, like a supervised classifier, training mode (black highlighted), where training data are used and test mode (orange highlighted) where test data are used. The initial part needs to be the same for the samples used to create the model (blue highlighted) and for test mode. The model is generated in the training mode and then is used with blind samples in the test mode to obtain the result of the wind-speed modeling (green highlighted).

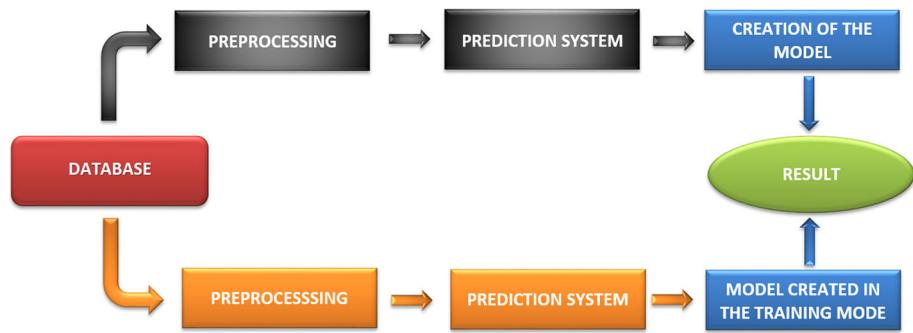
This prediction will serve to use it on a wind turbine, which, depending on its technical characteristics, could indicate the energy that could be produced.

## 2 Materials and methods

The database was provided by AEMET (private data set). This data set gives information relative to wind speed, temperature, precipitation, humidity, solar radiation, meteor, and cloudiness.

The reason why this database was chosen has to do, not only with the reliability of the institution, under the Ministry of Agricultural, Food and Environment of Spanish

**Fig. 1** Block sequence for the wind-speed prediction system  
(color figure online)



Government, but also with the location of both stations, near to areas where energy generation is possible and feasible.

AEMET provides information about meteorological phenomena in .xls file format. Each file contains data relative to one meteorological phenomenon for both stations (GC and TF) for a time period of 5 years, from 2003 to 2007. The sampling period of these stations is an hour.

The stations collected data from the meteorological phenomena studied in this research (precipitation, temperature, and wind speed) every hour. According to criteria explained in section C, other phenomena have been rejected. Table 1 shows the dimensions of each file, in terms of files (representing each hour of sampling) and columns (representing data corresponding to sensor name, year, month, day, location, altitude, longitude, latitude, hour, and meteorological phenomenon) of the .xls file.

To introduce data correctly into the ANN, it is necessary to follow the steps explained below. This is the preprocessing of the data obtained from AEMET meteorological stations.

## 2.1 Separating data from different stations

The information provided by AEMET in files with .xls extension contains data from both stations, GC and TF, together. It is necessary to divide this register into two different files, one per station, and repeat this procedure to the information of every phenomenon given by AEMET.

**Table 1** File dimensions

Meteorological phenomena	.xls dimension AEMET (rows × columns)
Humidity	3653 × 37
Meteor	121 × 52
Cloudiness	3653 × 18
Precipitation	3653 × 35
Radiation	1900 × 26
Temperature	3653 × 37
Wind speed	3652 × 60

Thereby, the research has been carried out in two different geographical locations.

## 2.2 Data review

Starting from the new files obtained in section A, it is possible to make a review of the data. In some cases, the station has no data of the meteorological phenomenon due to sensor failure, maintenance, or changes at the routine of data collection. These events are shown as blank data in file (e.g., there are no data for a period of time that can vary from 1 or 2 h to a full day).

When this situation is detected, the day involved in that eventuality is removed from the data. This is to not introduce false data into the ANN in the next step.

## 2.3 Joining data into Matlab

This is a significant step in the preprocessing stage. First, it is necessary to discover the phenomenon which gives maximum information; according to the absence of data, presence of data measured along time (i.e., there are data during the whole experiment). For that reason, some of the phenomena presented in AEMET files should be removed:

- *Humidity* Only in the last 2 years, the study presents data in a continuous way.
- *Meteor* This is a non-significant source for the study.
- *Cloudiness* The study does not present data in a continuous way during the day.
- *Solar radiation* Data are not presented in a continuous way during the day.

Second, data given by AEMET were adapted to more precise units at this stage and added to the new file. It results in precipitation (in tenths of a millimeter) from AEMET, temperature (in tenths of °C) from AEMET, wind speed (in kilometers per hour) from AEMET, temperature in °C, precipitation in millimeters, and wind speed in meters per second.

Once the data have been introduced, the result of wind-speed prediction was obtained using Matlab R2014a.

**Table 2** Samples per station

Year	Samples per station	
	GC	TF
2003	8755	8323
2004	8731	7819
2005	8755	8059
2006	8611	8131
2007	8587	8419

After adjusting data to be introduced correctly into ANN under Matlab environment, the number of samples per year and station in the resulting file is shown in Table 2. Thereafter, samples are introduced into Matlab. In this study, 84.190 samples are used to obtain an accurate wind-speed prediction in two different places.

Artificial Neural Network was the prediction system selected to this research. An ANN [23] is a machine designed to model the way in which the brain performs a particular task or function of interest. The network is simulated in software on a digital computer or implemented using electronic components. Neural networks employ a massive interconnection of simple computing cells referred to as neurons or processing units to achieve good performance.

ANNs have been used for modeling with good results in a lot of studies, for example, Li et al. [24] in application to hydrological and water resources modeling; Bakker et al. [25] in forecasting model for short-term drinking water demand; Valverde et al. [26] for rainfall forecasting.

ANNs are an information processing paradigm which is inspired by the biological nervous systems [27]. The key element of this paradigm is a new structure composed of a large number of highly interconnected processing elements (neurons), working together to solve specific problems. A neural network is a powerful data modeling tool that is able to capture and represent complex input–output relationships [28]. One of its types, Multilayer ANN, is a network consisting of multiple layers of action. For the proposed model, three layers are considered. The first one, input layer, receives information from external sources. The second one, hidden layer, is responsible for running the internal processes of the network. The third one, performance or output layer, is responsible for communicating the response of the system to the outside.

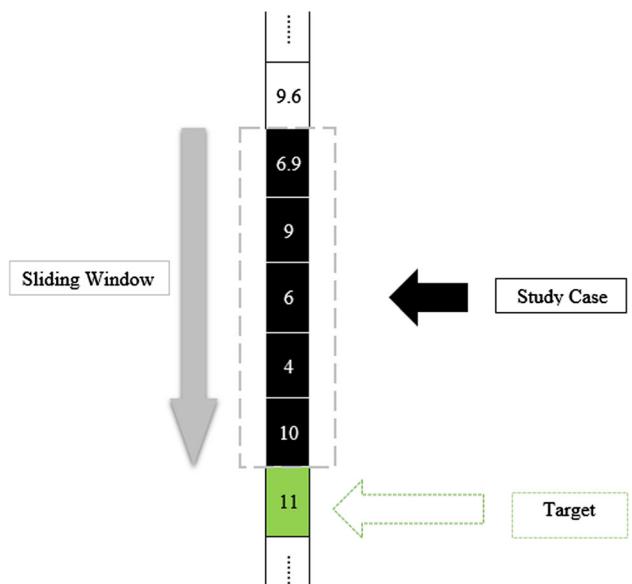
Each one of these layers is comprised of elementary processing units which are called artificial neurons. Each neuron has individually a certain number of entries, a processing node and a single output, and each connection between neurons is associated with a weight value [29]. ANNs are able to model the relationship between inputs and outputs by modifying the weight values of the connections. Therefore, an ANN is configured for a particular

application, such as pattern recognition or data classification, through a learning process. For this research, the back propagation method was used, which is characterized by a supervised learning type.

In this research, an Artificial Neural Network multilayer perceptron feed forward with backpropagation training algorithm was used as prediction system, with 24 neurons in the hidden layer and one neuron in the output layer. To reduce the resulting error, which leads to a better wind-speed prediction, backpropagation algorithm is used and the initialization of the ANN weights was randomly assigned. This configuration of the ANN was chosen from the different possibilities due to the results obtained by heuristic methods to obtain results with high accuracy.

The sliding window is a tool to adapt the system in order to obtain an accurate prediction. It contains a number of samples that leads to a value. This value indicates the wind speed predicted for the next hour. The sliding window used in this work is shown in Fig. 2, representing five samples of study on each data series (highlighted in black). The sliding window (gray dash highlighted) displaces one sample studying the data included in it, forming the study case (black highlighted) and thus obtaining the predicted value that must be closer to the target value (green highlighted).

To obtain a better wind-speed prediction, two ways are followed and explained below. First, using data provided by meteorological stations with the considerations explained before. Second, normalizing by decades (just dividing by 10, 20, or 100), we reduce the dispersion of data before introducing them into the ANN. Using this normalization, and reducing the dispersion, the ANN can reach a better weight modification of data leading to a better output result.

**Fig. 2** Sliding window (color figure online)

Our research is based on heuristic methods to test the system, using data from AEMET (wider reference values) or more precise data, to obtain the correct configuration of the ANN that leads to the right wind-speed prediction.

Treating to reach this aim, the experiments realized in this research are:

1. using unnormalized and normalized data from AEMET;
2. using more precise data from AEMET (unnormalized and normalized);
3. using different linked phenomena (unnormalized and normalized data fusion).

The values used to obtain predictions are, in all those cases, past values of the phenomena studied in the experiment, whether for an individual phenomenon as with linked phenomena.

In case of a single phenomenon which is involved in the simulation, Eq. (1) was used, where  $e(t)$  stands for the predicted value of a specific phenomenon (in our research wind speed) based only on past values of that phenomenon:

$$e(t) = f(y(t-1), \dots, y(t-d)). \quad (1)$$

Equation (2) was used when one phenomenon is used to predict another phenomenon, e.g., using temperature to predict wind speed. Predicted values of wind speed are represented by  $e(t)$  and past values of temperature are represented by  $x(t)$ . In this experiment, the previous values of  $e(t)$  are unknown:

$$e(t) = f(x(t-1), \dots, x(t-d)). \quad (2)$$

When different phenomena are involved and linked in the prediction of wind speed, the expression used was Eq. (3), where past values of all the involved phenomena are used to reach a prediction. In this expression, only two linked phenomena were used. For more phenomena, it is only necessary to add more variables to the function with the same procedure:

$$e(t) = f(y(t-1), \dots, y(t-d), x(t-1), \dots, x(t-d)). \quad (3)$$

During the research, several combinations were used and tested to obtain the best prediction depending on each phenomenon. When different phenomena were linked to make the experiments, the data set used was the corresponding to more precise data, based upon the results

obtained on experiments (1) and (2). To obtain the optimal number of hidden neurons and training iterations, heuristic methods were used. The ANN was trained using Neural Network Toolbox of Matlab and data from the year 2006. This year was chosen for training due to the number of samples included on it, closer to the average of samples of all the years of study. The test of the ANN was carried out with the remaining years of study. According to the results, and always based on heuristic methods, the best option to obtain a better precision on wind-speed prediction was verified.

### 3 Results

Results are presented in tables with the statistical parameters of minimum, maximum, mean absolute error (MAE), standard deviation (SD), and mean square error (MSE) for both stations (GC and TF), between the true value measured by the stations and the predicted value obtained with the ANN. The statistical that provides the goodness of prediction is the MAE to compare with the previous research cited before, but we present the rest of statistical values just for have another reference for future studies. To obtain each statistic parameter, results of the whole year have been used. It means that the MAE is not the best punctual value obtained in a year of study, but the best mean value of a whole year of study. In addition, time is given in milliseconds (ms) of training and test per sample (TPS). Although the data used are those provided by AEMET, results are always presented using more precise units.

To compare the true value measured for the meteorological station (in bold blue) and predicted value (in dashed red), figures are shown with samples (200) for the first 8 days of January of the year in which best results are reached. Only 8 days are represented in figures to demonstrate the high accuracy of the prediction model in a short time prediction, but the research also includes all year round. Depending on the experiment, the data used to obtain the predicted values will be expressed in the units given in Table 3.

**Table 3** Units of data used to obtain the predicted value

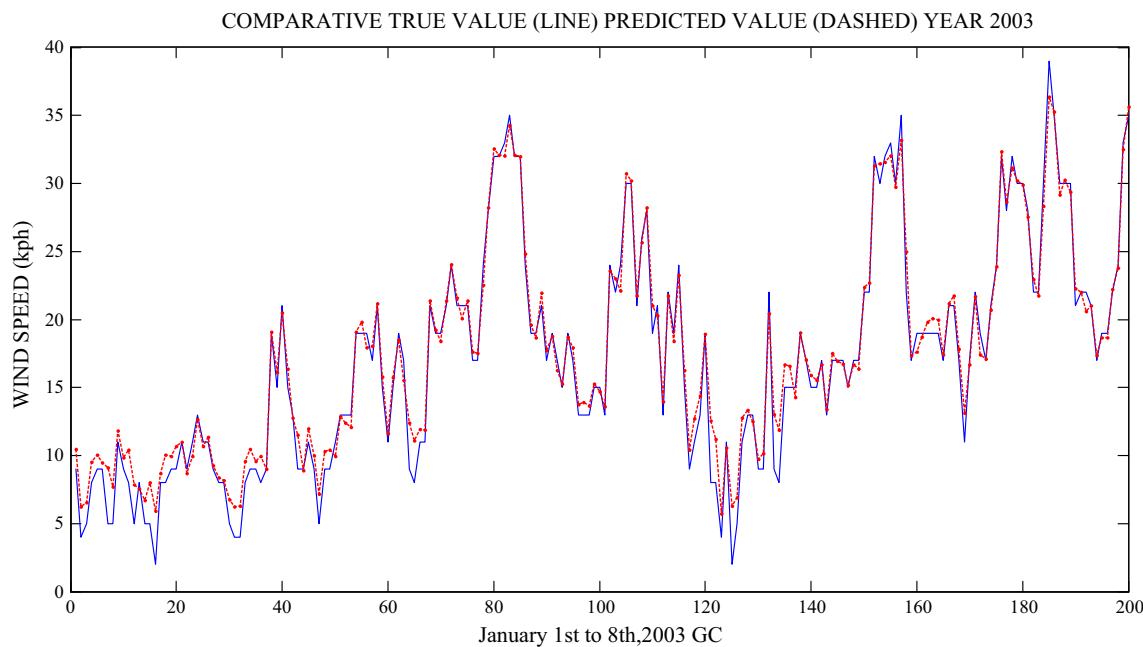
Phenomenon	Units of data used in the experiment	
	Data from AEMET	More precise data and data fusion
Temperature	Tenths of °C	°C
Wind speed	Kilometers per hour (kph)	Meters per second (mps)
Precipitation	Tenths of millimeters (mm)	Millimeters (mm)

**Table 4** Results using wind speed from AEMET GC station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$7.08 \times 10^{-5}$	$7.08 \times 10^{-5}$	$7.08 \times 10^{-5}$	$2.31 \times 10^{-5}$
Maximum	9.51	8.90	9.79	7.31
MAE	0.86	0.95	0.90	0.91
SD	0.81	0.85	0.83	0.81
MSE	1.18	1.28	1.22	1.22
Time (ms)	Train TPS	17,700 228		

**Table 5** Results using wind speed from AEMET TF station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$9.64 \times 10^{-6}$	$1.65 \times 10^{-5}$	$1.80 \times 10^{-5}$	$2.21 \times 10^{-4}$
Maximum	11.30	10.70	10.34	8.23
MAE	1.15	1.08	1.07	1.03
SD	1.15	1.02	1.04	0.95
MSE	1.62	1.49	1.49	1.40
Time (ms)	Train TPS	17,100 223		

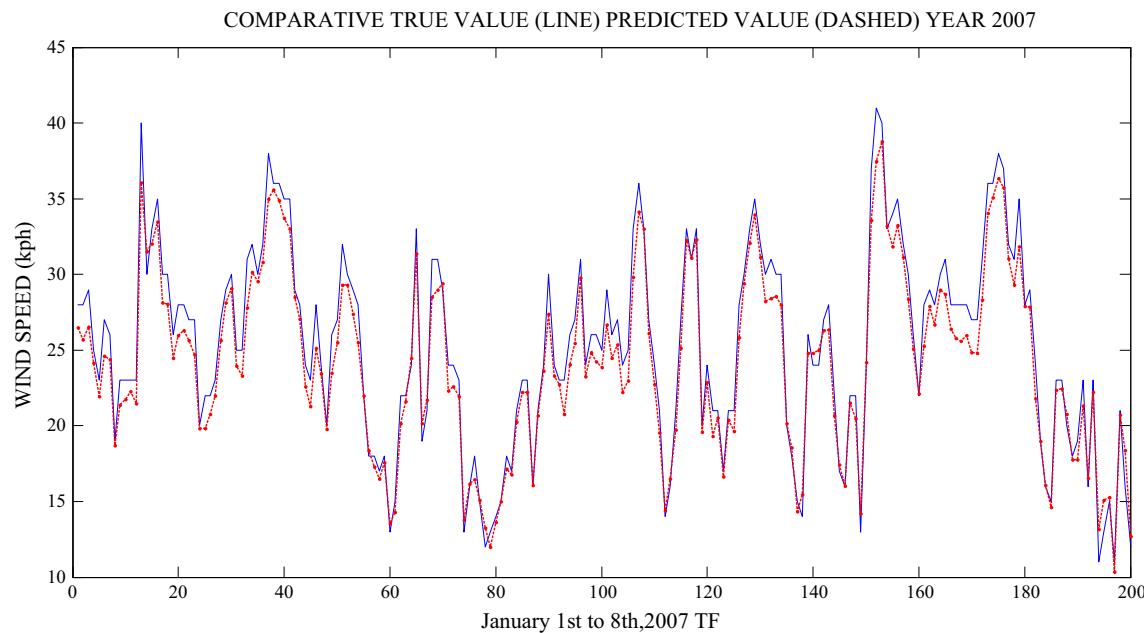
**Fig. 3** Comparative with wind speed from AEMET GC station as input data

### 3.1 Using data from AEMET

#### 3.1.1 Unnormalized

Results for AEMET GC station are shown in Table 4 using wind speed. For AEMET TF station, results are shown in

Table 5. Figures 3, 4 show the comparative between true and predictive values for both stations.



**Fig. 4** Comparative with wind speed from AEMET TF station as input data

**Table 6** Results using normalized wind speed from AEMET GC station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$2.47 \times 10^{-5}$	$2.47 \times 10^{-5}$	$2.47 \times 10^{-5}$	$3.18 \times 10^{-4}$
Maximum	356.93	73.21	441.39	77.23
MAE	1.15	1.30	1.20	1.09
SD	4.48	2.33	5.61	1.75
MSE	4.63	2.67	5.74	2.06
Time (ms)	Train	35,000		
	TPS	2.97		

**Table 7** Results using normalized wind speed from AEMET TF station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$1.22 \times 10^{-4}$	$1.29 \times 10^{-5}$	$8.85 \times 10^{-7}$	$5.38 \times 10^{-4}$
Maximum	111.31	93.75	104.46	94.46
MAE	1.78	1.51	1.51	1.44
SD	4.23	2.70	3.27	2.73
MSE	4.59	3.10	3.60	3.09
Time (ms)	Train	32,300		
	TPS	2.94		

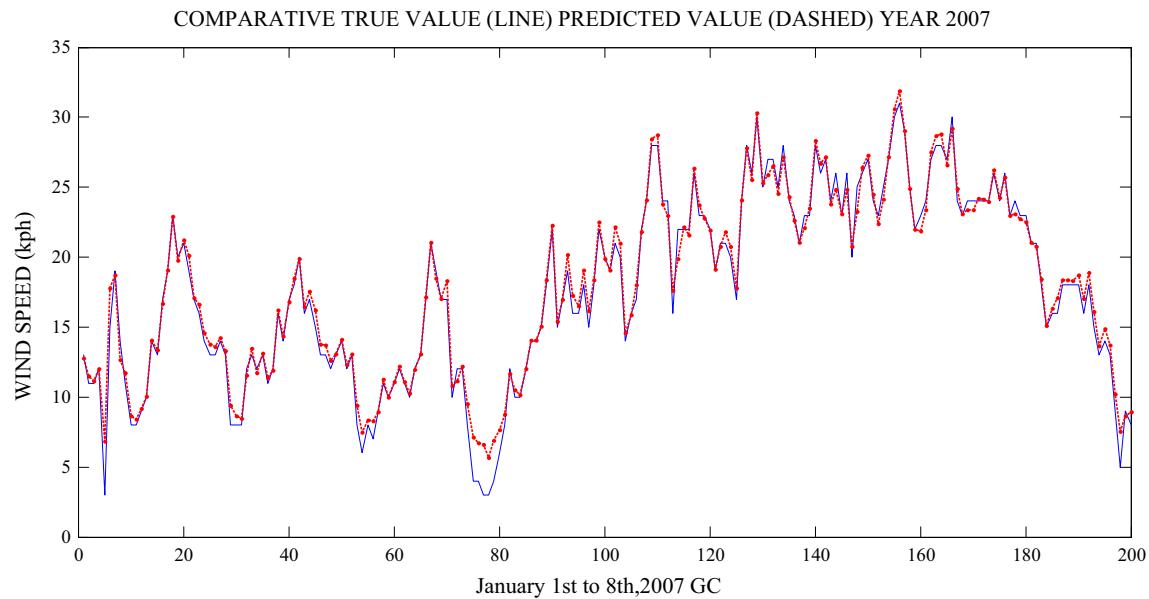
### 3.1.2 Normalized

Results from AEMET GC station using wind speed normalized by 100 are showed in Table 6. At AEMET TF station, results are as seen in Table 7 using normalization by 10. A comparison is shown in Figs. 5 and 6.

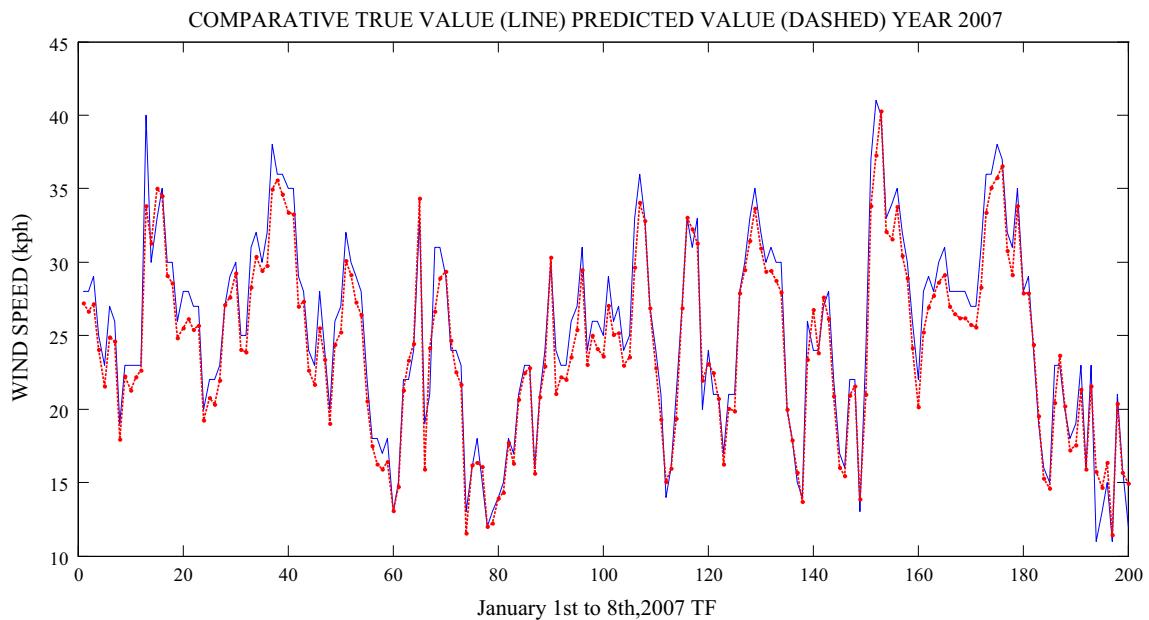
## 3.2 Using more precise data

### 3.2.1 Unnormalized

Results using data from AEMET GC station are shown in Table 8. Results from AEMET TF station are shown in



**Fig. 5** Comparative with wind speed from AEMET GC station using normalized data



**Fig. 6** Comparative with wind speed from AEMET TF station using normalized data

**Table 8** Results using wind speed from AEMET GC station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$2.67 \times 10^{-4}$	$7.24 \times 10^{-5}$	$6.34 \times 10^{-5}$	$4.37 \times 10^{-6}$
Maximum	9.54	9.15	10.90	7.29
MAE	0.85	0.95	0.89	0.91
SD	0.80	0.85	0.82	0.81
MSE	1.17	1.27	1.22	1.22
Time (ms)	Train	176,000		
	TPS	2.22		

**Table 9** Results using wind speed from AEMET TF station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$1.35 \times 10^{-4}$	$2.63 \times 10^{-5}$	$1.69 \times 10^{-4}$	$3.11 \times 10^{-4}$
Maximum	11.08	10.31	13.45	8.31
MAE	1.14	1.07	1.06	1.01
SD	1.15	1.01	1.03	0.94
MSE	1.62	1.48	1.48	1.39
Time (ms)	Train TPS	167,000 2.22		

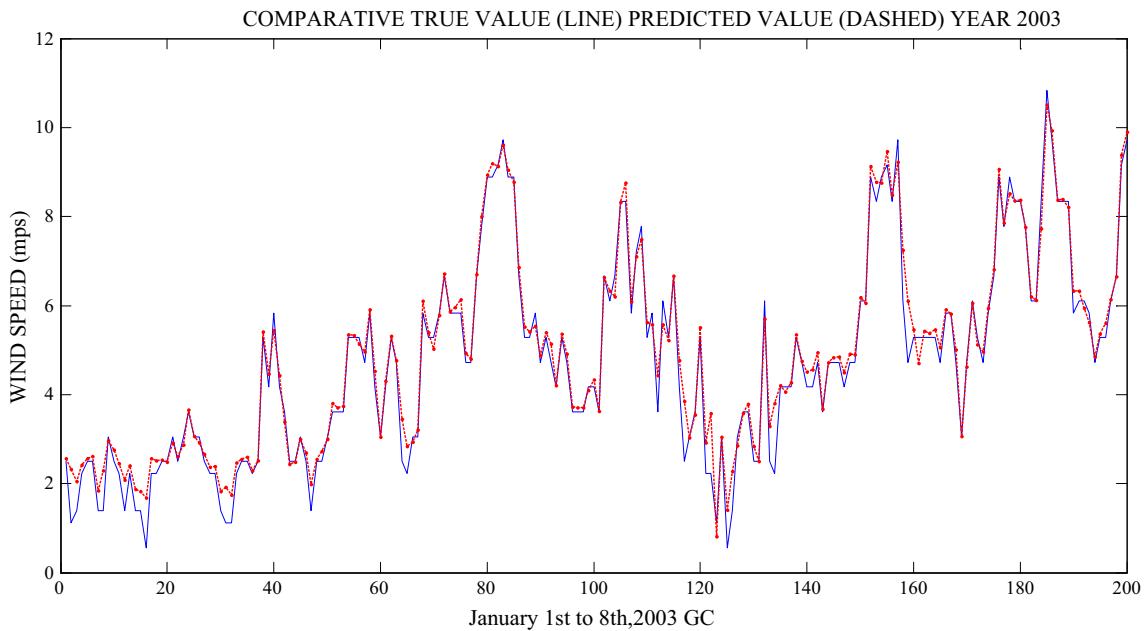
**Fig. 7** Comparative with wind speed using more precise units from AEMET GC station

Table 9. Comparative between true and predictive values are presented in Figs. 7 and 8.

### 3.2.2 Normalized

Table 10 displays the best results for AEMET GC station using normalization by 100. For AEMET TF station, the best results using normalized data by 20 are shown in Table 11. Finally, Figs. 9, 10 present the comparison between true and predictive values for both stations.

### 3.3 Using different linked phenomena (data fusion)

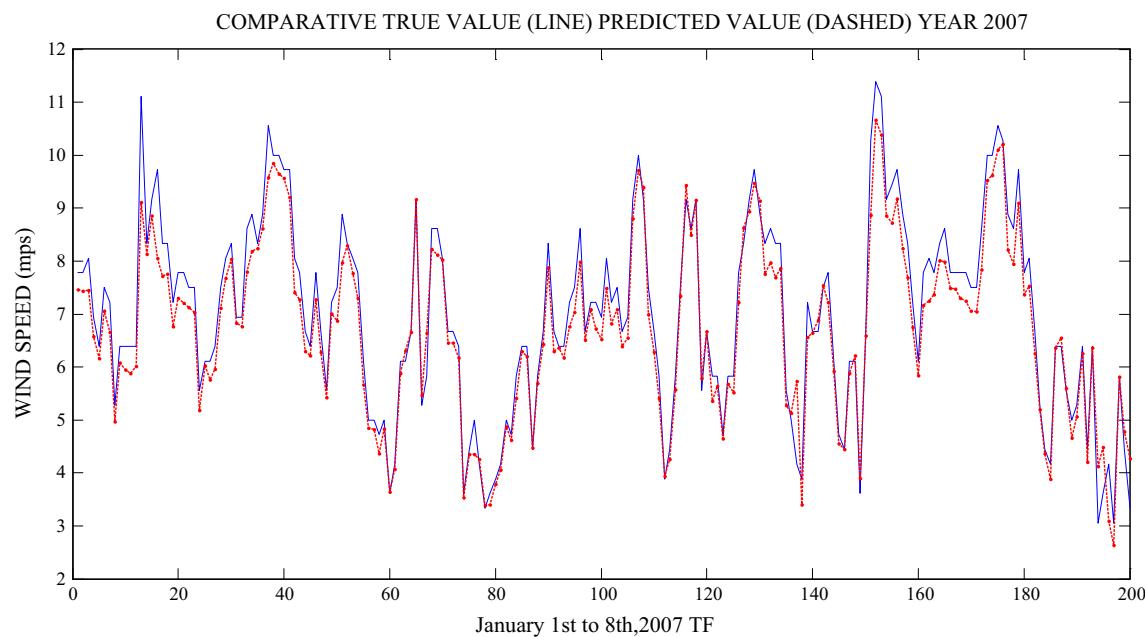
Units of inputs data are more precise providing better results than using data from AEMET. In these experiments, we are looking for the combination of meteorological phenomena that provide more information to the system to obtain a better prediction.

#### 3.3.1 Unnormalized

Best results in wind-speed prediction were reached when wind speed and temperature were involved in the experiment. Related to AEMET GC station, results are shown in Table 12. For AEMET TF station, results are shown in Table 13. Figures 11, 12 indicate the results of comparisons between true values and predictive values.

#### 3.3.2 Normalized

Best results were reached using wind speed and temperature normalized by 100 to predict wind speed at AEMET GC station, as shown in Table 14. From AEMET TF station, see Table 15, best results were obtained using wind speed and temperature. Comparisons for both stations are shown in Figs. 13 and 14. The accuracy of the system is compared to a persistence benchmark technique (forecasting no change); Diebold–Mariano test (DM) [30] is



**Fig. 8** Comparative with wind speed using more precise units from AEMET TF station

**Table 10** Results using wind speed with normalized data from AEMET GC station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$8.87 \times 10^{-5}$	$4.12 \times 10^{-5}$	$4.30 \times 10^{-5}$	$1.46 \times 10^{-5}$
Maximum	9.17	7.46	77.17	7.67
MAE	0.29	0.34	0.31	0.30
SD	0.39	0.45	0.93	0.37
MSE	0.49	0.56	0.98	0.48
Time (ms)	Train	35,200		
	TPS	2.98		

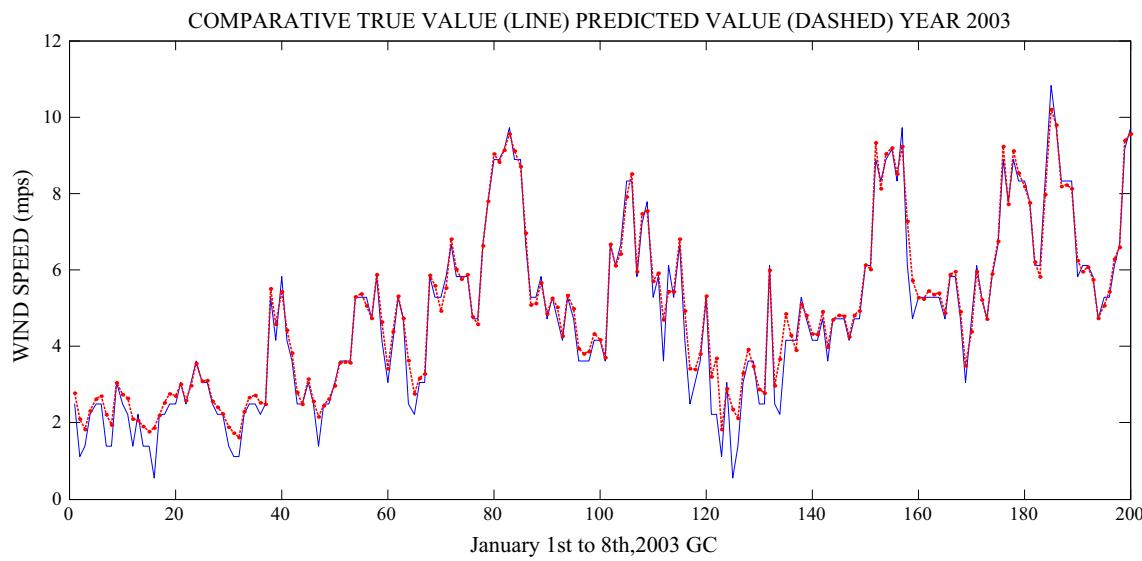
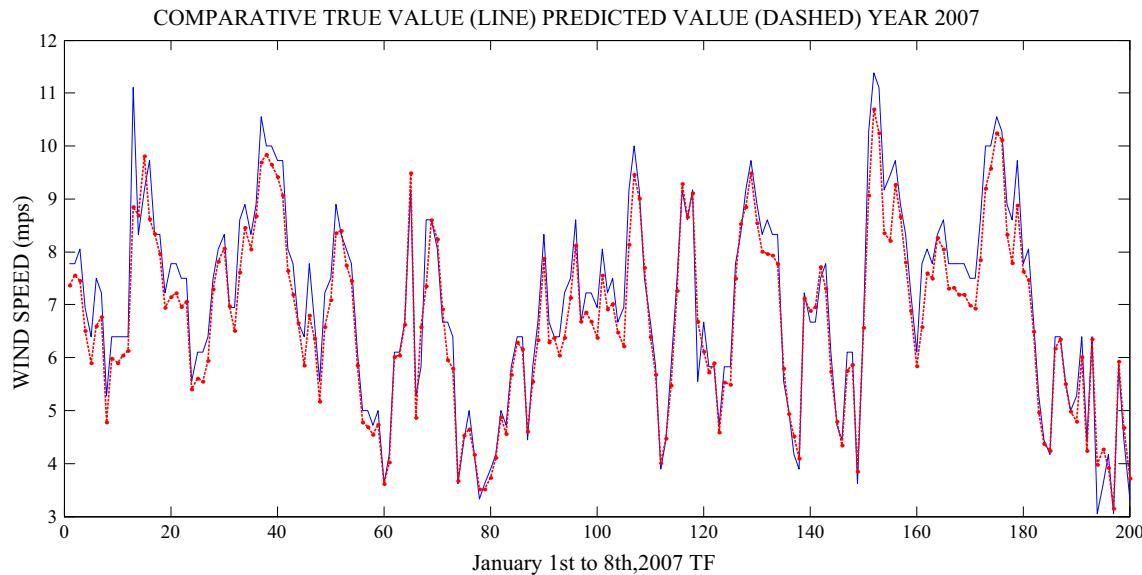
**Table 11** Results using wind speed with normalized data from AEMET TF station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$3.02 \times 10^{-5}$	$1.85 \times 10^{-5}$	$4.96 \times 10^{-6}$	$1.27 \times 10^{-5}$
Maximum	153.12	144.20	102.95	61.20
MAE	0.57	0.45	0.43	0.41
SD	3.23	1.96	1.51	0.94
MSE	3.28	2.01	1.57	1.02
Time (ms)	Train	32,300		
	TPS	2.97		

evaluated in this last model to show that this proposal outperforms the simple persistence benchmark forecaster as can be seen in the results of Tables 14 and 15.

#### 4 Discussion

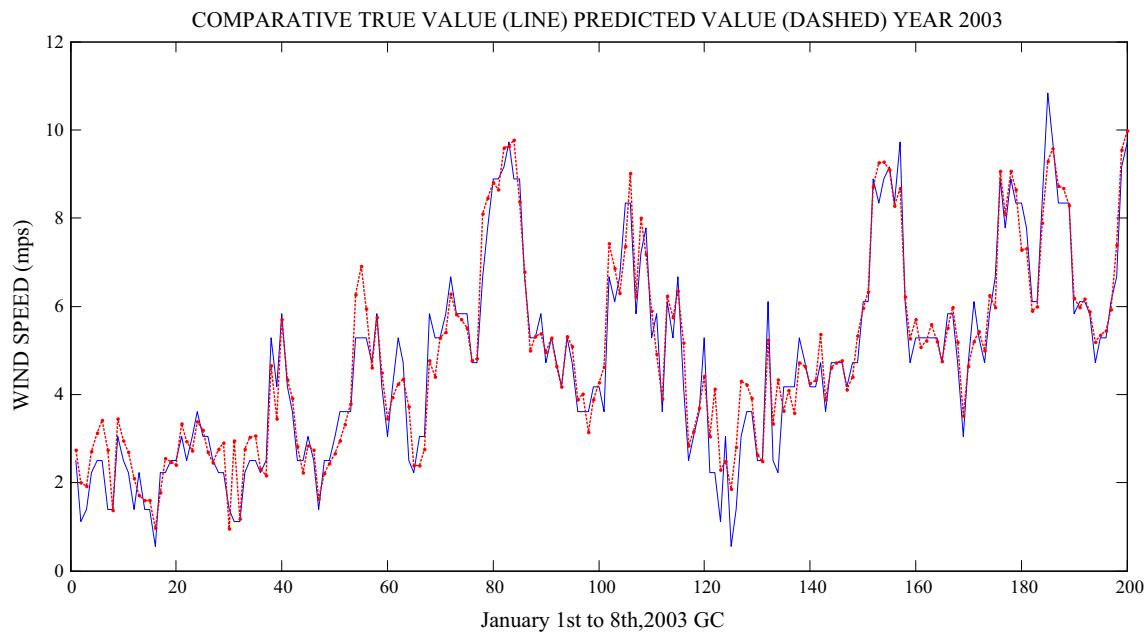
In terms of energy generation, it is possible to establish a relationship between wind speed and generated energy using the load curve of the turbine.

**Fig. 9** Comparative with wind speed from AEMET GC using normalized data**Fig. 10** Comparative with wind speed from AEMET TF using normalized data**Table 12** Results using wind speed and temperature from AEMET GC station

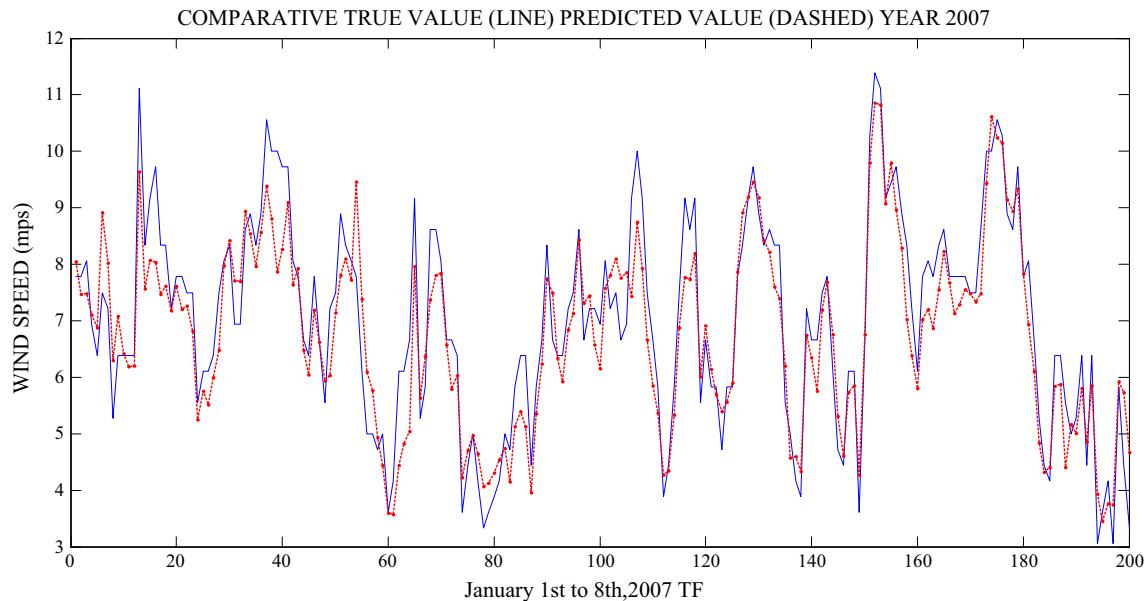
Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$3.77 \times 10^{-5}$	$6.87 \times 10^{-5}$	$5.00 \times 10^{-5}$	$2.50 \times 10^{-4}$
Maximum	9.54	9.77	12.41	7.20
MAE	0.84	0.91	0.85	0.88
SD	0.77	0.82	0.79	0.76
MSE	1.14	1.22	1.16	1.16
Time (ms)	Train TPS	132,000 211		

**Table 13** Results using wind speed and temperature from AEMET TF station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$8.85 \times 10^{-5}$	$6.36 \times 10^{-4}$	$4.24 \times 10^{-4}$	$2.97 \times 10^{-4}$
Maximum	10.64	10.83	13.04	9.27
MAE	1.11	1.04	1.03	0.99
SD	1.11	0.98	1.01	0.91
MSE	1.56	1.43	1.44	1.35
Time (ms)	Train TPS	126,000 211		



**Fig. 11** Comparative with wind speed and temperature for AEMET GC station



**Fig. 12** Comparative with wind speed and temperature for AEMET TF station

**Table 14** Results using wind speed and temperature with normalized data for AEMET GC station

Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$1.47 \times 10^{-6}$	$5.58 \times 10^{-6}$	$1.63 \times 10^{-4}$	$2.60 \times 10^{-4}$
Maximum	10.02	15.41	18.26	15.35
MAE	0.44	0.50	0.46	0.48
SD	0.48	0.67	0.60	0.53
MSE	0.66	0.75	0.75	0.71
DM	6.27 <sup>a</sup>	4.41 <sup>a</sup>	5.53 <sup>a</sup>	6.68 <sup>a</sup>
Time (ms)	Train	5990		
	TPS	3.56		

<sup>a</sup>Significance level of Diebold–Mariano test in 1%

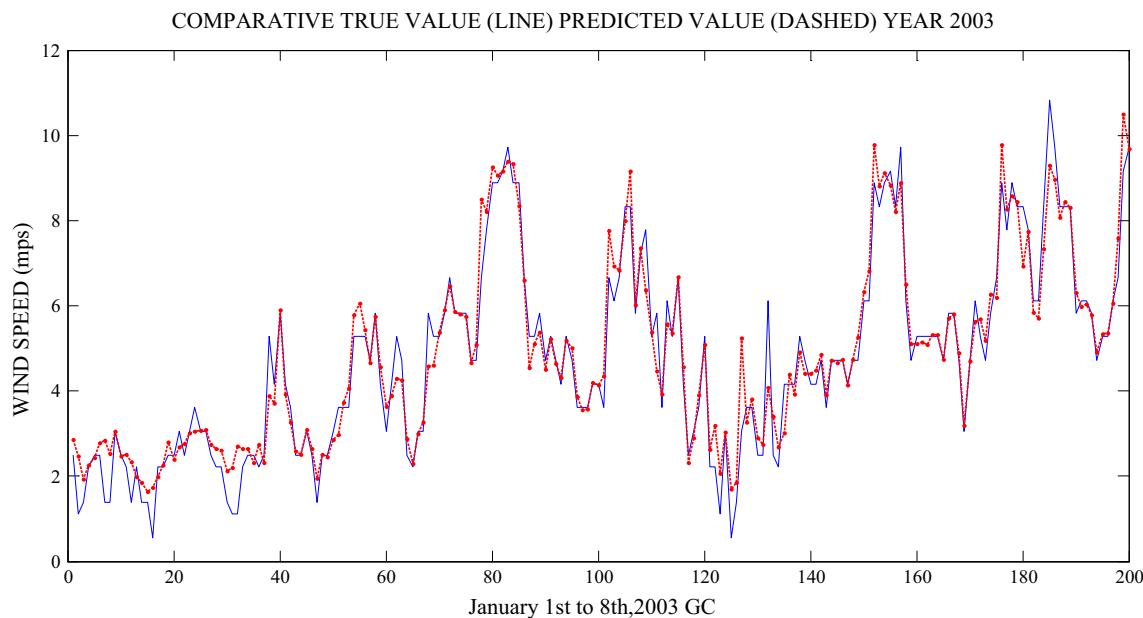
**Table 15** Results using wind speed and temperature with normalized data for AEMET TF station

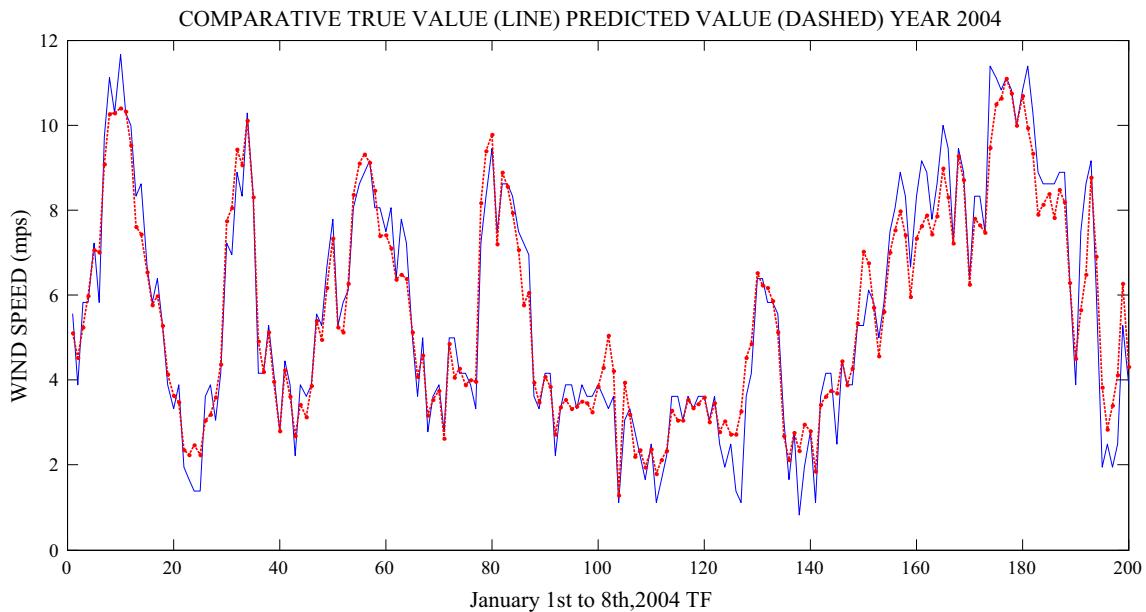
Statistical parameters	Prediction error in meters per second			
	Year 2003	Year 2004	Year 2005	Year 2007
Minimum	$2.11 \times 10^{-5}$	$2.77 \times 10^{-4}$	$1.02 \times 10^{-5}$	$5.83 \times 10^{-5}$
Maximum	379.12	77.85	440.54	398.57
MAE	0.80	0.63	0.77	0.66
SD	5.24	1.74	7.75	5.68
MSE	5.30	1.85	7.79	5.72
DM	2.57 <sup>a</sup>	4.37 <sup>a</sup>	3.56 <sup>a</sup>	4.76 <sup>a</sup>
Time (ms)	Train	5540		
	TPS	3.55		

<sup>a</sup>Significance level of Diebold–Mariano test in 1%

In particular, for Gamesa G52-850 Kw [31], the slope of the load curve indicates that a variation of 1 m/s corresponds to 100 kW of wind energy generated. According to

that, this research achieves an error of 0.29 m/s corresponding to 29 kW, or 3.43% of deviation. Table 16 shows

**Fig. 13** Comparative with wind speed and temperature for AEMET GC station using normalized data



**Fig. 14** Comparative with wind speed and temperature for AEMET TF station using normalized data

**Table 16** Comparative to the previous works using ANN:wind speed

Study	MAE in meters per second
Xingpei et al. [7]	1.33
Zhao et al. [8]	1.21
Tarade and Katti [9]	2.24
Bhaskar and Singh [10]	0.86
Nan et al. [11]	0.51
Chen et al. [12]	1.24
Li et al. [15]	0.55
Filik and Filik [16]	0.50
Our research	0.29

the comparison of this research with the previous studies presented in this article:

The sampling period of the previous works is 1 ms in [16], 10 min in [7, 11, 12], 10 min meaning data for each of the last 35 days in [8], hourly averaged 10 min wind speed in [10], and approximately 3 h for [9]; there is no information about sampling period in [15], compared to our hourly sampling period. Sampling period beyond an hour reveals bigger error in prediction.

This research shows an improvement over previous works and opens the way to further investigation.

## 5 Conclusions

Once the study is performed, it has been shown that the phenomena with more information to obtain a better wind-speed prediction are wind speed. On the other hand,

precipitation provided no relevant information for the correct wind speed prediction.

The result in this research is the mean value of the study of the whole year, not just the best result reached in the year of study, for a specific location.

The use of more precise units allows a better prediction compared to data from AEMET, 0.29 versus 0.86 m/s, respectively. Prediction times are short, as shown in the results tables in test times per sample.

The greatest strength of the model is that it is no necessary to have multiple data types to obtain a wind-speed prediction with great accuracy, i.e., although humidity, cloudiness, and solar radiation are very important variables, the system is able to acquire a good prediction with less data.

Versatility is another strength of the system, reaching a great accuracy in the prediction of several meteorological phenomena in different geographical locations, helping to generate green energy and reduce CO<sub>2</sub> emissions. This prediction will serve to use it on a wind turbine, which, depending on its technical characteristics, can make possible to know how much energy could produce.

Finally, the sampling period is another advantage compared to the previous works with lower sampling period, but with a higher error. Besides, the system can be an interesting tool for small power producers like enterprises or remote houses that can use green energy instead or in addition to energy from fossil fuels.

**Acknowledgements** This work has been supported by Endesa Foundation and the University of Las Palmas Foundation under Grant “Programa Innova Canarias 2020”.

## Compliance with ethical standards

**Conflict of interest** The authors declare that they have no conflict of interest. The funding sponsors had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, and in the decision to publish the results.

## References

- World Bank (2018) Percentage of fossil fuel energy consumed by countries. <http://datos.bancomundial.org/indicador/EG.USE.COMM.FO.ZS> Accessed 24 Mar 2018
- Cinco D (2018) Spanish economic journal founded in 1978. In: News on the European pact of energy. [http://cincodias.com/cin codias/2014/10/16/empresas/1413464789\\_240406.html](http://cincodias.com/cin codias/2014/10/16/empresas/1413464789_240406.html). Accessed 24 Mar 2018
- European Commission (2018) Environment action programme to 2020. <http://ec.europa.eu/environment/newprg/index.htm>. Accessed 24 Mar 2018
- United Nations (2017) Climate summit 2015. <http://www.cop21.gouv.fr/en/>. Accessed 19 Apr 2017
- United Nations. Climate Summit 2015. <http://www.un.org/sustainabledevelopment/cop21/> Accessed 24 March 2018
- Gorona del Viento (2018) Wind-hydro-pumped station of El Hierro. <http://www.goronadelviento.es/index.php>. Accessed 24 Mar 2018
- Xingpei L, Yibing L, Weidong X (2009) Wind speed prediction based on genetic neural network. In: 4th IEEE conference on industrial electronics and applications (ICIEA 2009), international conference center, Xi'an, P. R. China, 25–27 May 2009, pp 2448–2451. <https://doi.org/10.1109/iciea.2009.5138642>
- Zhao P, Xia J, Dai Y, He J (2010) Wind speed prediction using support vector regression. In: 5th IEEE conference on industrial electronics and applications (ICIEA 2010), Taichung, Taiwan, 15–17 June 2010, pp 882–886. <https://doi.org/10.1109/pes.2010.5589418>
- Tarade RS, Katti PK (2011) A comparative analysis for wind speed prediction. In: International conference on energy, automation, and signal (ICEAS). Siksha 'O' Anusandhan University Bhubaneswar, India, 28–30 December 2011, pp 1–6. <https://doi.org/10.1109/iceas.2011.6147167>
- Bhaskar K, Singh SN (2012) AWNN-assisted wind power forecasting using feed-forward neural network. *IEEE Trans Sustain Energy* 3(2):306–315. <https://doi.org/10.1109/TSTE.2011.2182215>
- Nan S, Su-quan Z, Xian-hui Z, Xun-wen S, Xiao-yan Z (2013) Wind speed forecasting based on grey predictor and genetic neural network models. In: International conference on measurement, information and control (ICMIC), vol 02. Harbin University of Science and Technology Building One No. 52 Xuefu Road Nangang District, Harbin, China, 16–18 August 2013, pp 1479–1482. <https://doi.org/10.1109/mic.2013.6758238>
- Chen N, Qian Z, Nabney IT, Meng X (2014) Wind power forecasts using gaussian processes and numerical weather prediction. *IEEE Trans Power Syst* 29(2):656–665. <https://doi.org/10.1109/TPWRS.2013.2282366>
- Yoshida S, Suzuki H, Kitajima T, Kassim AM, Yasuno T (2016) Correction method of wind speed prediction system using predicted wind speed fluctuation. In: 55th annual conference of the society of instrument and control engineers of Japan (SICE), Tsukuba International Congress Center, Tsukuba, Japan, 20–23 September 2016, pp 1054–1059. <https://doi.org/10.1109/sice.2016.7749245>
- Mert İ, Karakuş C, Üneş F (2016) Estimating the energy production of the wind turbine using artificial neural network. *Neural Comput Appl* 27:1231. <https://doi.org/10.1007/s00521-015-1921-0>
- Li J, Wang R, Zhang T (2016) Wind speed prediction using a cooperative coevolution genetic algorithm based on back propagation neural network. In: IEEE world congress on evolutionary computation (CEC), Vancouver, BC, 24–29 July 2016, pp 4578–4583. <https://doi.org/10.1109/cec.2016.7744373>
- Filik UB, Filik T (2017) Wind speed prediction using artificial neural networks based on multiple local measurements in Eskisehir. *Energy Proc* 107:264–269. <https://doi.org/10.1016/j.egypro.2016.12.147>
- Ulkat D, Günay ME (2017) Prediction of mean monthly wind speed and optimization of wind power by artificial neural networks using geographical and atmospheric variables: case of Aegean Region of Turkey. *Neural Comput Appl*. <https://doi.org/10.1007/s00521-017-2895-x>
- Gemesa (2018) Case of study: Arinaga. In: A project come true. <http://pdf.archiexpo.com/pdf/gemesa-electric/case-study-arinaga/88576-242524.html>. Accessed 24 Mar 2018
- Gemesa (2018) off-shore turbine in Arinaga beats generation record. <http://www.gamesacorp.com/es/cargarAplicacionNoticia.do?idCategoria=59&identificador=1042&urlAmigable=the-g128-50-mw-offshore-beats-power-generation-record-for-a-wind-turbine-in-spain.html>. Accessed 24 Mar 2018
- Office of Energy Efficiency and Renewable Energy (2018) U.S. Department of Energy. How do wind turbines survive severe storms? <https://www.energy.gov/eere/articles/how-do-wind-turbines-survive-severe-storms>. Accessed 24 Mar 2018
- Professional Windsurfers Association (PWA) (2017) Events of the PWA world tour calendar 2017 <http://www.pwaworldtour.com/index.php?id=2151>. Accessed 18 Feb 2017
- Asociación Empresarial Eólica (2017) The Spanish Wind Energy Association. <http://www.aeeolica.org/es/map/canarias/>. Accessed 18 Feb 2017
- Haykin S (1999) Neural networks. In: A comprehensive foundation, 2nd edn. Prentice Hall Inc., United States of America
- Li X, Zecchin AC, Maier HR (2014) Selection of smoothing parameter estimators for general regression neural networks: applications to hydrological and water resources modelling. *Environ Model Softw* 59:162–186. <https://doi.org/10.1016/j.envsoft.2014.05.010>
- Bakker M, Vreeburg JHG, van Schagen KM, Rietveld LC (2013) A fully adaptive forecasting model for short-term drinking water demand. *Environ Model Softw* 48:141–151. <https://doi.org/10.1016/j.envsoft.2013.06.012>
- Valverde MC, Araujo E, Campos Velho H (2014) Neural network and fuzzy logic statistical downscaling of atmospheric circulation-type specific weather pattern for rainfall forecasting. *Appl Soft Comput* 22:681–694. <https://doi.org/10.1016/j.asoc.2014.02.025>
- Hernández-Travieso JG, Herrera-Jiménez AL, Travieso-González CM, Morgado-Díaz F, Alonso-Hernández JB, Ravelo-García AG (2017) Temperature control by its forecasting applying score fusion for sustainable development. *Sustainability* 9:193
- Devi CJ, Reddy PBS, Kumar KV, Reddy BM, Nayak RN (2012) ANN approach for weather prediction using Backpropagation. *Int J Eng Trends Technol* 3:19–23
- Serrano A, Soria E, Martín J (2009) Redes Neuronales Artificiales. Universidad de Valencia (Escuela Técnica Superior Ingeniería, Departamento de Ingeniería Electrónica), Valencia
- Diebold FX, Mariano RS (1995) Comparing predictive accuracy. *J Bus Econ Stat* 13:253–263
- Gemesa (2018) G52-850 KW Technical Information. <http://www.wind-power-program.com/Library/Turbine%20leaflets/Gemesa/Gemesa%20G52%20850kw.pdf>. Accessed 24 Mar 2018



Neural networks fusion for temperature forecasting

**Revista:** Neural Computing and Applications.

**JCR 2017:** IF: 4.213, 15/132, Q1 (Computer Science, Artificial Intelligence).

**Publicación online:** 22 de marzo de 2018.

**URL:** <https://link.springer.com/article/10.1007/s00521-018-3450-0>

*Neural networks fusion for temperature forecasting*

**Received: 18 January 2018 / Accepted: 16 March 2018**  
© The Natural Computing Applications Forum 2018

**Keywords** Score fusion · Modeling · Temperature prediction · Artificial neural networks

**Abstract**  
Weather conditions have a direct relationship with energy consumption, touristic activities, and farm tasks. By means of the fusion of artificial neural networks, this work presents a system with a general method that obtains an accurate temperature prediction. The objective is temperature, but the method is easily scalable to obtain any other meteorological parameter; this is one strength of the model. This research carries out a temperature prediction modeling that contributes to obtain better results with different applications as energy generation or in other different fields such as tourism or farming. The database contains data of 5 years from stations located in Gran Canaria at Gran Canaria Airport and in Tenerife at Tenerife Sur Airport. Data are collected hourly, what means more than 100,000 samples. This quantity of samples gives sturdiness to the study. With this method, our best result in terms of mean absolute error and using data from meteorological stations in Canary Islands is 0.41 °C.

**1 Introduction**  
This work presents a novel method of fusion of artificial neural networks (ANN) in order to obtain a temperature forecasting. Using most voted method, this proposal can be applied to the improvement in energy generation process and to the increase in the use of renewable energy.

Currently, sources like petroleum derived or carbon are the most used in the energy generation process [1], leading to an increase in the use of fossil fuels [1].

In addition, efficiency in the generation process in Spain and Portugal in 2013 was only of 39.20% [2] using fossil fuels compared to 80% from hydraulic power [3], representing clearly the interest of using renewable energy to obtain a better efficiency in the generation process.

It is our duty to confront that reality and reconvert it by means of the use of clean energy source. Thenby, it could be possible to reduce CO<sub>2</sub> emissions, increasing efficiency in the energy generation and bringing energy to remote areas. Brede and de Vries [4] made an interesting study that explores long-term optimal investment allocations in a simple economy-energy-climate model, showing that depending on richness of the country and climate variations, the country will invest different amount of money in fossil fuel or renewable energy.

**Authors' contributions**  
José Gustavo Hernández-Travieso<sup>1</sup> • Antonio G. Ravelo-García<sup>2</sup> • Jesús B. Alonso-Hernández<sup>3</sup> • Carlos M. Travieso-González<sup>2</sup>

**Editor responsible** Antonio G. Ravelo-García

**Editor-in-Chief** Antonio G. Ravelo-García

**Volume** 15 **Number** 3 **September** 2014

**ISSN** 0941-0643  
**Neural Comput & Applic**  
DOI 10.1007/s00521-018-3450-0

**Springer**

**ONLINE FIRST**

**Neural Computing & Applications**

**Springer**



# Neural networks fusion for temperature forecasting

José Gustavo Hernández-Travieso<sup>1</sup>  · Antonio G. Ravelo-García<sup>2</sup>  · Jesús B. Alonso-Hernández<sup>3</sup>  · Carlos M. Travieso-González<sup>3</sup> 

Received: 18 January 2018 / Accepted: 16 March 2018  
© The Natural Computing Applications Forum 2018

## Abstract

Weather conditions have a direct relationship with energy consumption, touristic activities, and farm tasks. By means of the fusion of artificial neural networks, this work presents a system with a general method that obtains an accurate temperature prediction. The objective is temperature, but the method is easily scalable to obtain any other meteorological parameter; this is one strength of the model. This research carries out a temperature prediction modeling that contributes to obtain better results with different applications as energy generation or in other different fields such as tourism or farming. The database contains data of 5 years from stations located in Gran Canaria at Gran Canaria Airport and in Tenerife at Tenerife Sur Airport. Data are collected hourly, what means more than 100,000 samples. This quantity of samples gives sturdiness to the study. With this method, our best result in terms of mean absolute error and using data from meteorological stations in Canary Islands is 0.41 °C.

**Keywords** Score fusion · Modeling · Temperature prediction · Artificial neural networks

## 1 Introduction

This work presents a novel method of fusion of artificial neural networks (ANN) in order to obtain a temperature forecasting. Using most voted method, this proposal can be applied to the improvement in energy generation process and to the increase in the use of renewable energy.

Currently, sources like petroleum derived or carbon are the most used in the energy generation process [1], leading to an increase in temperature and greenhouse effect.

In addition, efficiency in the generation process in Spain and Portugal in 2013 was only of 39.20% [2] using fossil fuels compared to 80% from hydraulic power [3], representing clearly the interest of using renewable energy to obtain a better efficiency in the generation process.

It is our duty to confront that reality and reconvert it by means of the use of clean energy source. Thereby, it could be possible to reduce CO<sub>2</sub> emissions, increasing efficiency in the energy generation and bringing energy to remote areas. Brede and de Vries [4] made an interesting study that explores long-term optimal investment allocations in a simple economy-energy-climate model, showing that depending on richness of the country and climate variations, the country will invest different amount of money in fossil fuel or renewable energy.

---

✉ José Gustavo Hernández-Travieso  
jose.hernandez149@alu.ulpgc.es  
Antonio G. Ravelo-García  
antonio.ravelo@ulpgc.es  
Jesús B. Alonso-Hernández  
jesus.alonso@ulpgc.es  
Carlos M. Travieso-González  
carlos.travieso@ulpgc.es

<sup>1</sup> Institute for Technological Development and Innovation in Communications (IDeTIC), University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, 35017 Las Palmas de Gran Canaria, Spain

<sup>2</sup> Signal and Communications Department, University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, sn, Ed. de Telecommunicación, Pabellón B, 35017 Las Palmas de Gran Canaria, Spain

<sup>3</sup> Signal and Communications Department, Institute for Technological Development and Innovation in Communications (IDeTIC), University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, sn, Ed. de Telecommunicación, Pabellón B, Despacho 111, 35017 Las Palmas de Gran Canaria, Spain

In Canary Islands (Spain), we can see an example of this thanks to a station that uses wind energy to create a water movement between two tanks located at different heights [5]. El Hierro is the island where this station is situated and allows the wind energy to move the water from the lower tank to the higher tank and then the electricity is generated by the movement of water from the higher to the lower tank. This allows the island to use clean sources in the energy generation process. The benefits of using renewable energy in El Hierro not only reduce the economic cost of generating energy from diesel (about 6000 tonnes, which is equal to 40,000 barrels of oil), creating a savings of over 1.8 million euros a year, but also contributes to the environment, avoiding the yearly emission of 18,700 tonnes of CO<sub>2</sub>, 100 tonnes of sulfur dioxide, and 400 tonnes of nitrogen oxides.

Along the years, various works have been carried out in this area and here we present some of them. Ellouz et al. [6] using ANN proposed a tool that will help to evaluate the aspects of heat exchange between earth and air using soil pipe buried to heating or cooling passively a building in Sfax (Tunisia). This tool improved meteorological conditions inside the building and also reduced energetic costs.

Shu et al. [7] considering weather predictions could establish a relationship between temperature and electricity demand forecasting for an electric utility in the Midwest US with precision. Rastogi et al. [8] worked with pattern analysis to predict temperature using ANN. Obtained results showed the efficiency of the proposed model, representing the behavior of the temperature prediction with accuracy.

Chen and Xu [9] made a model based on ANN to predict temperature and air humidity in coal mines roadways. The prediction errors were into the range required by the project. Routh et al. [10] presented an application of ANN to predict temperature and its impact on solar cells taking into consideration that this is one important factor in solar panel efficiency.

Huang, Chen et al. [11], using ANN, probed that thermal behavior of buildings may vary nonlinearly depending on conditions such as outside temperature, number of people. The model was tested at terminal building of Adelaide Airport (Australia) and will help to increase energy efficiency in buildings, reducing cost of heating, ventilation, and air conditioning systems. Xingpei et al. [12] used ANN to make a wind speed prediction. Zhao et al. [13] used support vector regression (SVR) and ANN (with back-propagation algorithm) to obtain a wind speed prediction. Tarade and Katti [14] obtained an accurate short-term prediction model applied to wind speed. They used autoregressive integrated moving average (ARIMA), ANN, and polynomial curve fitting model. Bhaskar and Singh

[15] used ANN with adaptive wavelet and feed-forward algorithms to make a forecasting of wind power.

Shi et al. [16] by means of genetic ANN and grey models improved the forecasting of wind speed. This method was applied to a wind farm. Chen et al. [17] made an investigation to obtain predictions of wind power with 1 day in advance combining probabilistic and numerical models. Ruffin and Venayagamoorthy [18] by means of echo state networks (ESN) obtained solar irradiance predictions from 30 to 270 min in advance. Naing and Srinivasan [19] used ANN and mathematical prediction models to obtain an estimation of solar radiation. In that study, geographical and meteorological data were used. The correlation between real values and estimated values was high.

Wang et al. [20] used an optimization of wavelet ANN to forecast solar radiation. Wu and Keon [21] made an hourly prediction of solar radiation by means of time-delay neural networks and autoregressive moving average model (ARMA). Salcedo-Sanz et al. [22] estimated solar radiation evaluating Gaussian process regression.

Baptista et al. [23] made a hardware implementation of an ANN to predict the energy production of a photovoltaic system. They obtained a mean square error of 0.0880464 corresponding to an error of 0.007%.

Hernández-Travieso et al. [24] used in 2017 score fusion of ANN to obtain temperature forecasting using data from Costa Rica. In this study, they obtained a mean square error of 0.136 °C.

This is an interesting area, as seen in the number of related works cited above and developed recently. In an attempt to contribute in this area, this work helps, on the one hand, to increase the efficiency during the process of energy generation since precise temperature prediction helps to reduce the cost of power generation by means of fossil fuels, reducing CO<sub>2</sub> emissions and making buildings more efficient. On the other hand, it could be an impulse to green energy generation, due to the use and combination of energy obtained by means of wind and sun. Besides, it could be used as an added value product for tourism, allowing the enterprises to do their activities in the right moment.

This contribution could be feasible thanks to the design and subsequent implementation of neural networks fusion. Meteorological data were obtained from the stations that the Meteorological State Agency (Agencia Estatal de Meteorología, AEMET) has at Gran Canaria (GC) Airport (Gran Canaria, Canary Islands) and at Tenerife Sur (TF) Airport (Tenerife, Canary Islands).

Figure 1 introduces the diagram block of the temperature prediction system.

**Fig. 1** Temperature prediction system



## 2 Preprocessing

The process to obtain a precise temperature prediction starts with a specific way to introduce the meteorological data into the classification system employed (ANN). This requires the three steps presented below.

### 2.1 Separating data from different stations

Data from AEMET provide information in one .xls file, containing meteorological information for GC and TF stations together. First step of preprocessing is to separate information, creating one .xls file per station allowing the realization of two studies, one per station, separately.

### 2.2 Data review

Events like sensor failure, changes in data collection routines, or anything else that could affect data collection lead to a period of time where data are not collected that can vary from one or 2 h to even a day. For that reason, the day in which those events appear has been removed, avoiding the introduction of false or wrong data to the system. Figure 2 shows an example, where temperature data (in tenths of °C) corresponding to June 9, 2006 from 2 am to 7 am are missing (highlighted in yellow).

### 2.3 Joining data into MATLAB

The last step in the preprocessing stage is the introduction in MATLAB environment of the data once they are joined correctly. Firstly, we have to investigate which phenomenon provides more information (i.e., existence of

194	194	194	193	192	191	195	205	221	227
205	204							219	212
201	201	200	200	201	197	195	196	210	223

**Fig. 2** Example of failure in the acquisition of temperature data (color figure online)

**Fig. 3** Example of .txt file of November 10, 2007 introduced in MATLAB

2007	11	10	16	0	241	15	2.41000e+001	0	4.166667e+000	40	1.111111e-001
2007	11	10	17	0	226	21	2.26000e+001	0	5.833333e+000	1	2.777778e-003
2007	11	10	18	0	217	19	2.17000e+001	0	5.277778e+000	0	0

acquired data along the period of time). Due to this, some phenomena have been erased from the file.

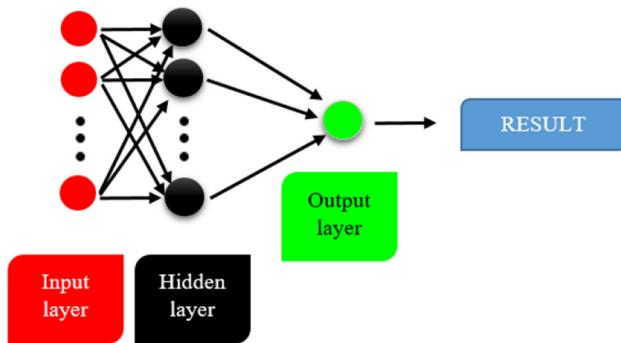
- *Humidity* Data for the years 2006 and 2007.
- *Meteor* It is a nonsignificant meteorological variable in this study.
- *Cloudiness* Data are not presented continuously during the day.

Finally, it is necessary to transform the .xls file obtained in a .txt file using MATLAB. The .txt file is the one that has been introduced in MATLAB environment to obtain the temperature prediction of this study. Figure 3 shows an example of the resulting .txt file that represents data of November 10, 2007, from 16 to 18 h. Starting from left, each column stands for year, month, day, hour, precipitation (in tenths of a millimeter) from AEMET, temperature (in tenths of °C) from AEMET, wind speed (in kilometers per hour) from AEMET, temperature in °C, precipitation in millimeters, wind speed in meters per second, solar radiation (in tenths of kilojoules per square meter) from AEMET, solar radiation in kilowatts hour per square meter.

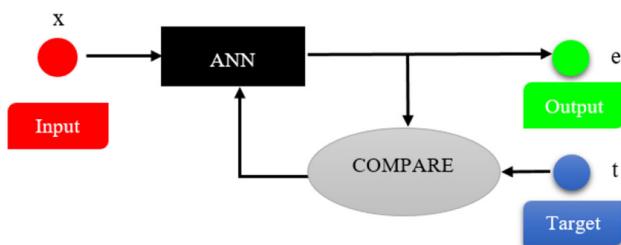
## 3 Prediction system

This work uses artificial neural network as prediction system. An ANN [25] is a machine that is designed to model the way in which the brain performs a particular task or function of interest. It can be implemented by means of electronics components or in a computer using software. To achieve good performance, neural networks employ a massive interconnection of simple computing cells referred to as neurons or processing units. Figure 4 represents the general approach of an ANN.

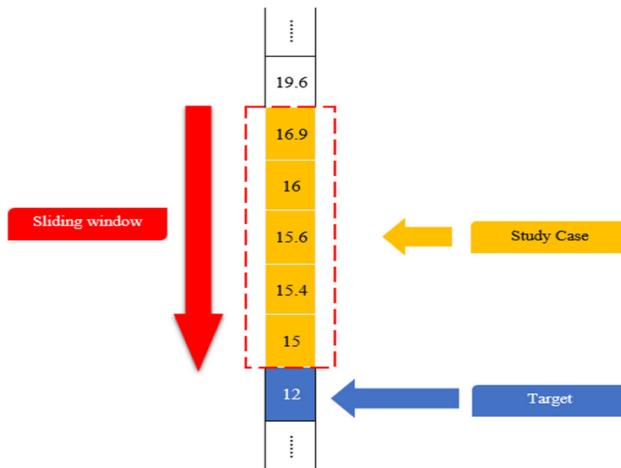
ANNs have been used for modeling with good results in a lot of studies, for example, Li et al. [26] in application to hydrological and water resources modeling; Bakker et al. [27] in forecasting model for short-term drinking water demand; and Valverde et al. [28] for rainfall forecasting.



**Fig. 4** General approach for ANN



**Fig. 5** ANN backpropagation algorithm



**Fig. 6** Example of sliding window

ANN multilayer perceptron feed forward with back-propagation training algorithm with twenty-four neurons

on the hidden lawyer and one neuron on the output lawyer is used in this study. In order to reduce the resulting error, backpropagation algorithm is used, leading to a better temperature prediction. We used a backpropagation approach, which is based on a Levenberg–Marquardt algorithm. The Levenberg–Marquardt algorithm was designed to approach second-order training speed without having to compute the Hessian matrix that presents second-order partial derivatives.

According to heuristic methods and the results obtained, this ANN configuration has been used. Figure 5 represents the ANN with backpropagation algorithm.

Figure 6 introduces the sliding window used in this work, with the configuration that offers better results, with five samples of study on each data series (highlighted in yellow). The window (highlighted in red) moves from one sample to another studying the value included on it. This creates the study case, allowing to obtain the predicted value, which must be closer to the target value highlighted in blue.

## 4 Experimental methodology

### 4.1 Database

In this work, data collected by stations depending of AEMET have been used. The data contained on it were wind speed, precipitation, humidity, temperature, solar radiation, cloudiness, and meteor.

The reason to use this paid database was the situation of the stations included in the study, with areas where the possibility to generate green energy is possible, and for the reliability of the institution, AEMET, depending on the Spanish Government.

Each meteorological phenomenon was included in a unique .xls file with data from both stations (GC and TF), as cited above, and for a period of 5 years, starting in 2003 and finishing in 2007.

Data from temperature, precipitation, solar radiation, and wind speed were collected hourly for the specific sensor located in each station. According to the criteria

**Table 1** Resulting number of samples after preprocessing

Year	GC		TF	
	With radiation	Without radiation	With radiation	Without radiation
2003	–	8755	1344	8323
2004	4064	8731	2960	7819
2005	1296	8755	3104	8059
2006	1952	8611	5424	8131
2007	3232	8587	5568	8419

explained in 2.3, other phenomena have not been included in the study.

## 4.2 Experiments

Once the preprocessing stage has finished, the data are introduced into MATLAB environment to be processed with the ANN. Table 1 shows the resulting samples number per station once the data were preprocessed correctly. Column WITH RADIATION includes the number of samples used when the phenomena involved are temperature, precipitation, wind speed, and radiation. Column WITHOUT RADIATION includes the number of samples used when the phenomena involved on the prediction are temperature, precipitation, and wind speed.

The reason why there are two different numbers of samples is that radiation has no data for the whole time of study. On the one hand, to predict temperature and wind speed, best results were obtained with no radiation data. On the other hand, to predict radiation, the number of samples has been reduced due to the limited data provided by AEMET in the files. Even so, the system has been tested under those new conditions to check soundness, not only to predict radiation, but also to predict other phenomena.

The present research follows two different ways with the aim of obtaining an accurate temperature forecasting. Firstly, the prediction is reached just by doing the experiment one time [with the equations explained later and marked as (1), (2), (3)], obtaining predicted values for solar radiation, temperature, and wind speed.

Secondly, we use the most voted method, which consists in the repetition of the whole data processing, i.e., training and testing, of all data for a specific number of repetitions. During the experiment, the value of MAE will be reduced until the moment in which it remains constant. This time, the experiments were repeated 100 times and the final result is obtained by doing the mathematical media of the intermediate results reached by each repetition, this is what we call fusion. This allows an improvement in the results acquired when the experiment was done just one time.

Applying heuristic methods, we probe to introduce information using data from AEMET (not corresponding to SI) or more precise data (corresponding to SI).

According to this, experiments cited below have been made:

1. Using data from AEMET.
  - (a) One time.
  - (b) Most voted method.
2. Using more precise data.
  - (a) One time.
  - (b) Most voted method.
3. Using different phenomena linked: data fusion.
  - (a) One time.
  - (b) Most voted method.

In the whole study, past values of each phenomena involved in the experiment were used.

In case just one phenomenon is involved in the experiment, the expression used was (1) where  $e(t)$  stands for the value to predict an specific phenomenon (temperature, wind speed, or solar radiation) based only on past values of that phenomenon:

$$e(t) = f(y(t-1), \dots, y(t-d)) \quad (1)$$

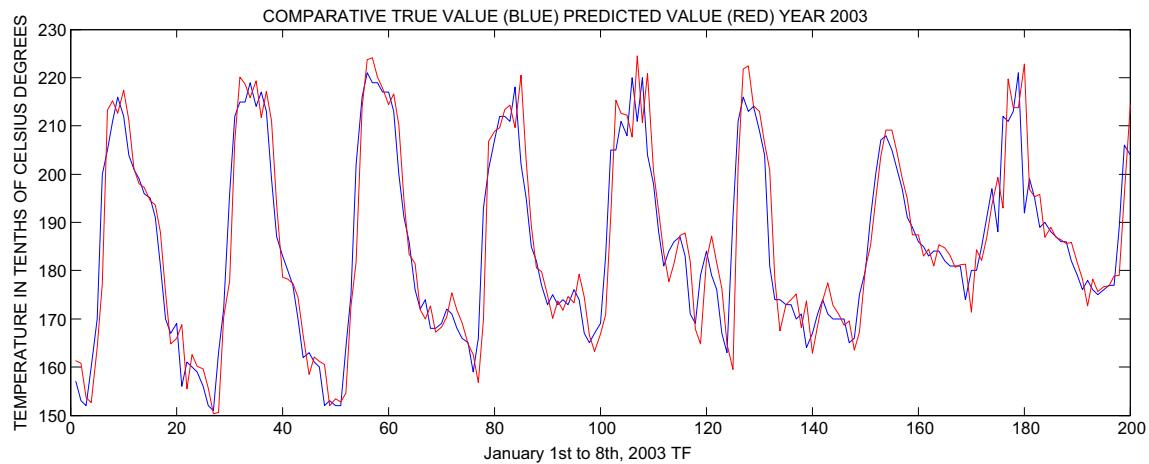
Expression (2) was used when one phenomenon is used to predict another phenomenon, for example, using precipitation to predict temperature, the predicted values of temperature are represented by  $e(t)$ , and the past values of precipitation are represented by  $x(t)$ . In this experiment, previous values of  $e(t)$  are unknown:

$$e(t) = f(x(t-1), \dots, x(t-d)) \quad (2)$$

When two or more phenomena were linked, the corresponding expression was (3). As in the previous expressions (1) and (2), the values involved in the experiment were past values of each phenomenon. In expression (3), only two phenomena linked were used, and for more phenomena, just add another variable to the function with the same procedure:

**Table 2** Units of data used to obtain the predicted value

Phenomena	Units of data used on the experiment	
	Data from AEMET	More precise data and data fusion
Temperature	Tenths of °C	°C
Wind Speed	Kilometers per hour (kph)	Meters per second (mps)
Solar radiation	Tenths of kilojoules per square meter (kJ/m <sup>2</sup> )	Kilowatts hour per square meter (kWh/m <sup>2</sup> )



**Fig. 7** Temperature GC

**Table 3** Results using temperature

Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$1.00 \times 10^{-4}$	$3.17 \times 10^{-5}$	$2.00 \times 10^{-4}$	$2.07 \times 10^{-5}$
MAX	8.87	8.89	5.91	4.74
MAE	0.44	0.50	0.46	0.48
SD	0.47	0.56	0.48	0.49
MSE	0.64	0.75	0.67	0.68
Time (s)	Train	32.5		
	Test per sample	$2.85 \times 10^{-3}$		

**Table 4** Results using temperature

Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$1.84 \times 10^{-5}$	$2.36 \times 10^{-5}$	$1.50 \times 10^{-4}$	$8.03 \times 10^{-5}$
MAX	4.54	7.05	6.12	4.67
MAE	0.42	0.49	0.45	0.46
SD	0.46	0.55	0.47	0.48
MSE	0.62	0.73	0.65	0.67
Time (s)	Train	$3.06 \times 10^3$		
	Test per sample	$2.81 \times 10^{-3}$		

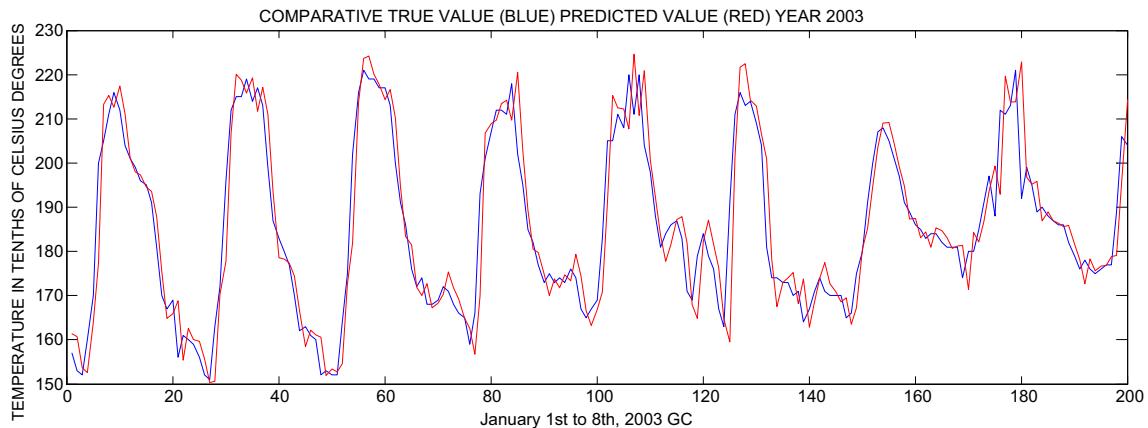
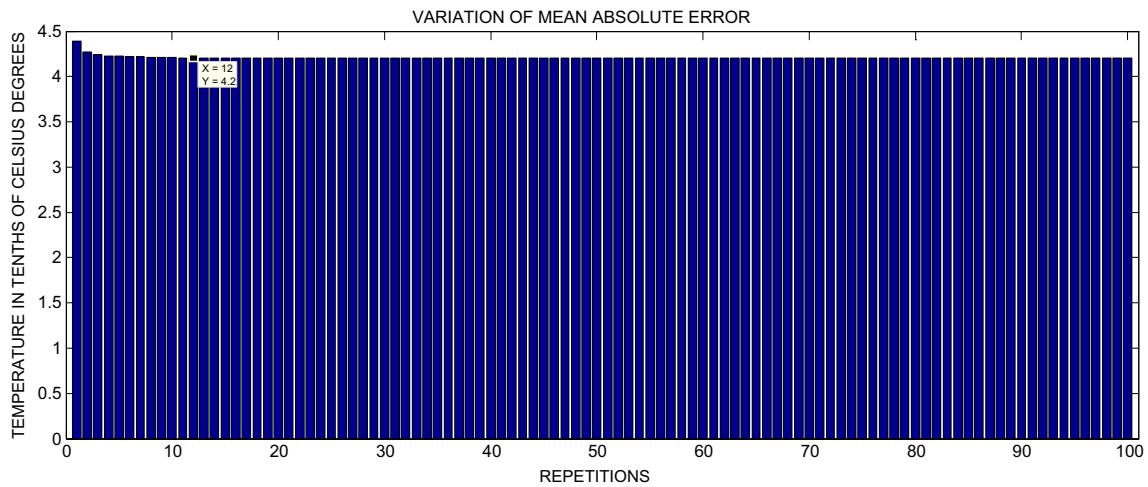
$$e(t) = f(y(t-1), \dots, y(t-d), x(t-1), \dots, x(t-d)) \quad (3)$$

In this work, several combinations were used and tested in order to obtain the best prediction depending on each phenomenon. When different phenomena were linked (fusion data), it has reached more precise data based on experiments (1), (2); that shows that more precise data obtain better results.

To obtain the specific configuration of the ANN in terms of iterations to train the ANN and correct number of hidden neurons, heuristic methods were applied.

Using MATLAB's neural network toolbox, the system was trained. According to the number of samples included, near to the average number of samples of all years included in the study, the year 2006 was used to train the ANN. For testing the ANN, the rest of the years included in the study were used. This is one of the strong points of the system, we train the system only with 20% of samples, and then we test it with the 80% of the samples.

The best combination of phenomena that leads to an accurate temperature prediction was chosen according to the results obtained by the application of heuristic methods.

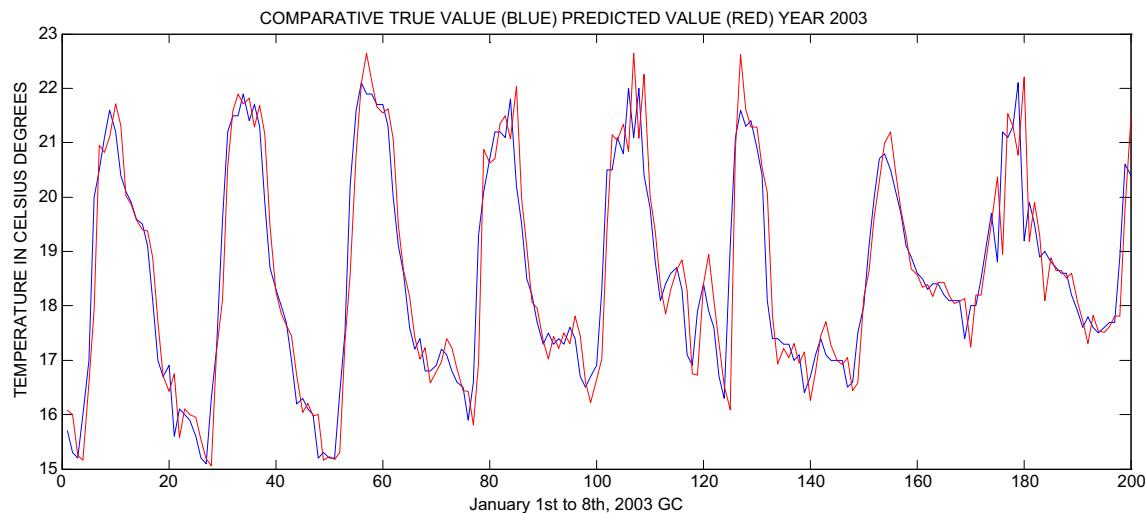
**Fig. 8** Temperature GC using most voted method**Fig. 9** Variation of MAE with temperature from GC using most voted method**Table 5** Results using temperature

Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$8.96 \times 10^{-5}$	$3.35 \times 10^{-5}$	$3.97 \times 10^{-5}$	$1.74 \times 10^{-6}$
MAX	8.11	7.07	6.85	4.77
MAE	0.42	0.49	0.45	0.46
SD	0.48	0.55	0.48	0.46
MSE	0.64	0.74	0.66	0.67
Time (s)	Train	$4.02 \times 10^2$		
	Test per sample	$9.05 \times 10^{-3}$		

## 5 Results

For each experiment, a table shows the results with the statistical parameters of minimum (MIN), maximum (MAX), mean absolute error (MAE), standard deviation (SD), and mean square error (MSE), for the station (GC or TF) that achieves better result, between the true value

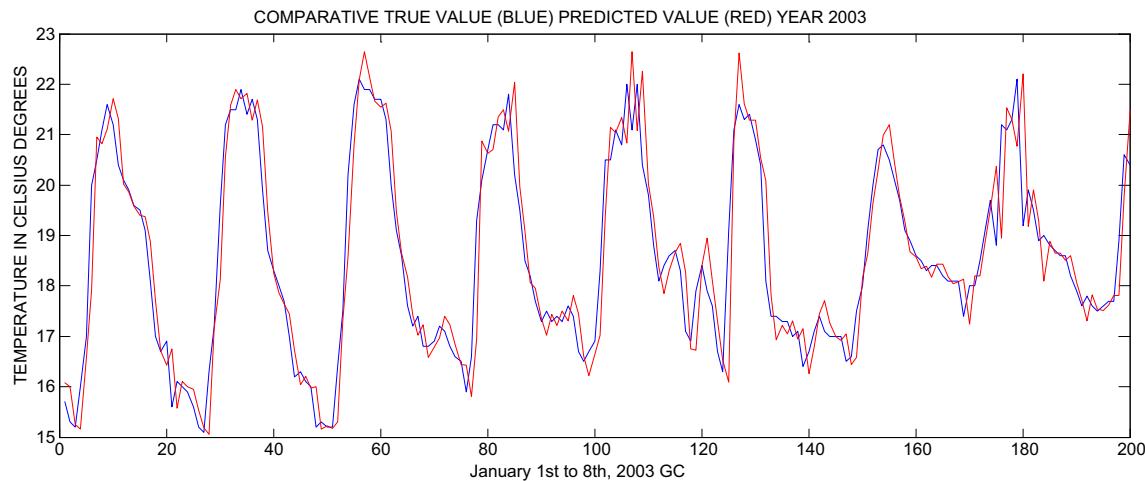
measured by the stations and the predicted value obtained with the ANN. The statistic that gives the goodness of prediction is the MAE. In addition, the times are given in seconds (s) of training and test per sample. The results are presented always using more precise units, although the data used are those provided by AEMET. Moreover, training time represents the time used to train the system



**Fig. 10** Temperature GC using more precise units

**Table 6** Results using temperature

Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$1.60 \times 10^{-4}$	$1.18 \times 10^{-5}$	$5.36 \times 10^{-5}$	$1.26 \times 10^{-4}$
MAX	4.49	7.54	6.44	4.69
MAE	0.41	0.49	0.44	0.46
SD	0.46	0.55	0.47	0.48
MSE	0.62	0.74	0.65	0.66
Time (s)	Train	$20.70 \times 10^2$		
	Test per sample	$20.62 \times 10^{-3}$		



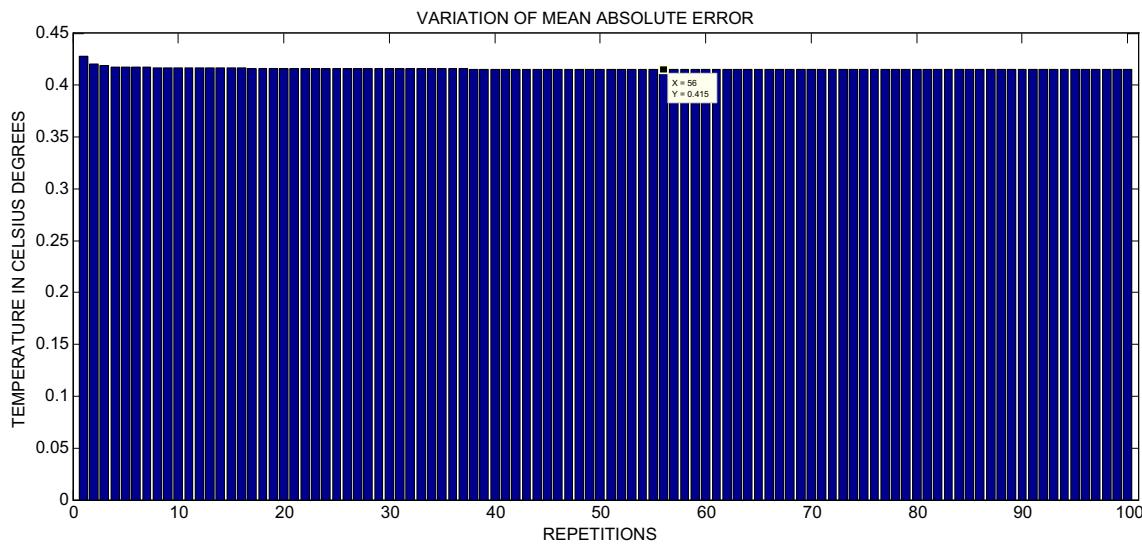
**Fig. 11** Temperature GC using most voted method

and test per sample represents the time in which a sample is processed. Both times are represented in seconds.

In addition, the figures are presented as a comparison. The true value is represented in blue and the predicted value represented in red by the samples (200) for the first

8 days of January of the year with better results. Table 2 presents the units used on each experiment according to the data involved in it:

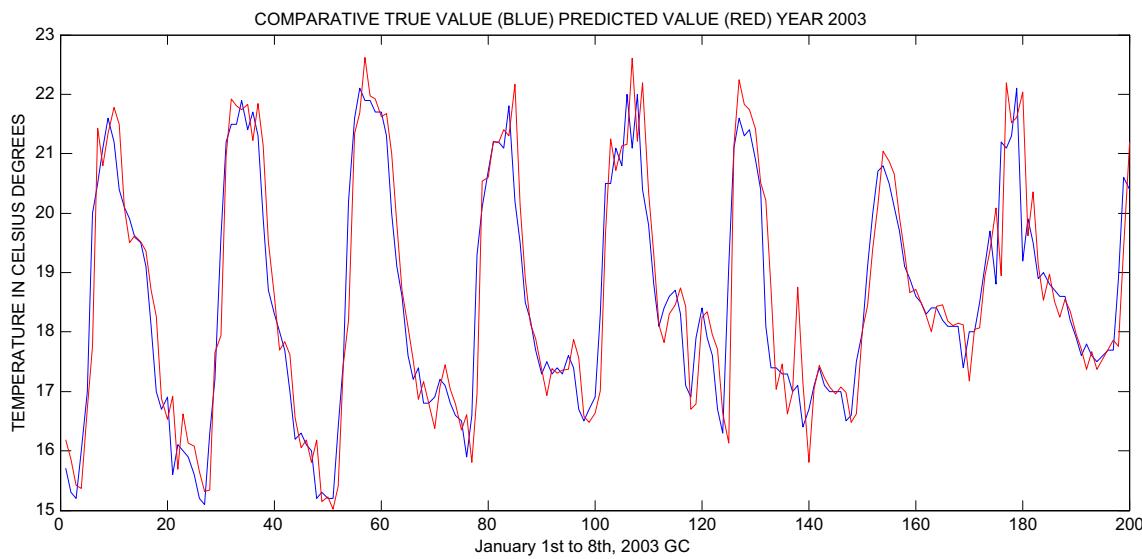
For the most voted method, another figure including the variation in the mean absolute error with each repetition is



**Fig. 12** Variation of MAE with temperature from GC using most voted method

**Table 7** Results using temperature, precipitation, and wind speed to predict temperature

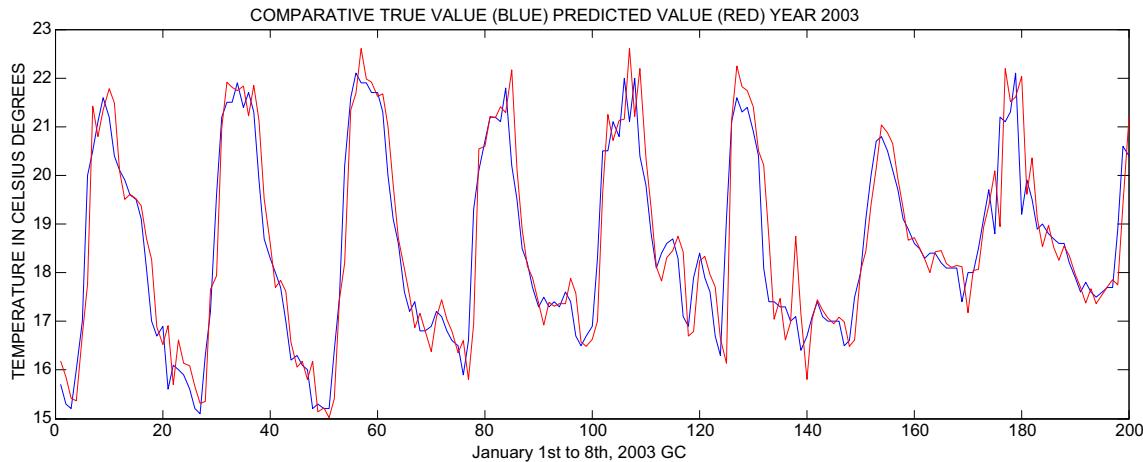
Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$5.42 \times 10^{-5}$	$1.44 \times 10^{-5}$	$1.77 \times 10^{-4}$	$7.49 \times 10^{-5}$
MAX	4.55	6.50	5.67	4.60
MAE	0.44	0.51	0.47	0.48
SD	0.45	0.47	0.48	0.48
MSE	0.64	0.48	0.67	0.68
Time (s)	Train	$1.78 \times 10^2$		
	Test per sample	$2.21 \times 10^{-2}$		



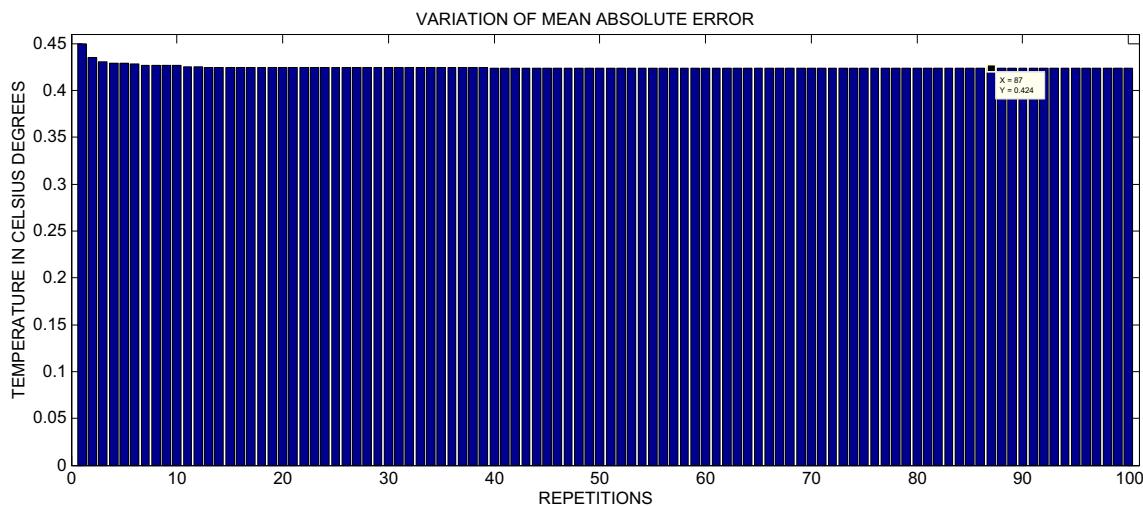
**Fig. 13** Temperature GC using temperature, precipitation, and wind speed

**Table 8** Results using temperature, precipitation, and wind speed to predict temperature

Statistical parameters	Prediction error in °C			
	Year 2003	Year 2004	Year 2005	Year 2007
MIN	$1.19 \times 10^{-5}$	$5.08 \times 10^{-5}$	$2.36 \times 10^{-5}$	$2.14 \times 10^{-5}$
MAX	4.57	7.28	6.13	4.55
MAE	0.42	0.49	0.44	0.46
SD	0.45	0.55	0.47	0.47
MSE	0.62	0.73	0.65	0.66
Time (s)	Train	$34.24 \times 10^2$		
	Test per sample	$2.12 \times 10^{-3}$		



**Fig. 14** Temperature GC using temperature, precipitation, and wind speed with most voted method



**Fig. 15** Variation of MAE with temperature from GC using temperature, precipitation, and wind speed with most voted method

presented. This allows to check the improvement in the system by using this method. Moreover, in this case, the results showed correspond to the best result reached by the experiment, for example, repetition that achieves best results.

## 5.1 Using data from AEMET

### 5.1.1 One time

With the data of GC station from the year 2003, best result reached was 0.44 °C, as shown in Fig. 7 and Table 3.

**Table 9** Comparison with previous researches

References	Error of prediction
[6]	1 °C
[7]	2 °C
[9]	0.2–4.9%
[11]	1 °C
[24]	0.13 °C
Our research (with most voted method and fusion of ANN)	0.41 °C

### 5.1.2 Most voted method

In this case, train time represents the train of the whole experiment (100 times) and the meaning of test per sample does not vary from other experiments. Table 4 and Fig. 8 show results from the repetition that reaches best result at GC station at repetition 12 with 0.42 °C in 2003, and Fig. 9 shows the variation of MAE in tenths of Celsius degrees.

## 5.2 Using more precise data

### 5.2.1 One time

A MAE of 0.42 °C was the best result of the experiment at GC station in 2003, as shown in Table 5 and Fig. 10.

### 5.2.2 Most voted method

In this case, train time represents the train of the whole experiment (100 times) and the meaning of test per sample does not vary from other experiments. Table 6 shows results from the repetition number 56 that reaches the best result with 0.41 °C as shown in Figs. 11 and 12.

## 5.3 Using different phenomena linked: data fusion

Units of inputs data are more precise, because using these data gives better results than using data from AEMET. In these experiments, we are looking for the combination of meteorological phenomena that gives more information to the system in order to obtain a better prediction.

### 5.3.1 One time

When temperature, precipitation, and wind speed are involved in temperature prediction, best results are achieved as shown in Table 7 and Fig. 13 with 0.44 °C.

### 5.3.2 Most voted method

In these experiments, data combination used in data fusion was the same of previous experiments. In addition, the

criteria used in tables and figures were the same as the previous experiments using most voted method.

At GC station using temperature, precipitation, and wind speed, the best results predicting temperature were reached in repetition 87 with a MAE of 0.42 °C as shown in Table 8 and Figs. 14 and 15.

## 6 Conclusions

This work probe that the novel use of fusion of ANN by means of most voted method achieves better results than when a single ANN is used 0.41 versus 0.42 °C.

Regarding temperature forecasting, precipitation presents less information when temperature is the phenomenon to predict. Contrarily, when precipitation is joined to temperature and wind speed, best results are reached, checking again that using more precise units allows to obtain a best prediction over data from AEMET, 0.41 versus 0.42 °C.

To have an idea of the goodness of the system, Table 9 introduces a comparison between our work and previous related works.

This is a quick system, able to obtain an accurate temperature prediction in terms of milliseconds, as seen in TPS parameter in the results tables.

Versatility is another strength of the system. The system presents great accuracy to predict several meteorological phenomena in different geographical locations, helping to generate green energy and reduce CO<sub>2</sub> emissions. Besides, it can be a tool for small power producers like enterprises or remote houses that want to use green energy instead or in addition to energy from fossil fuels.

**Acknowledgements** This work has been supported by Endesa Foundation and the University of Las Palmas Foundation under Grant “Programa Innova Canarias 2020.”

## Compliance with ethical standards

**Conflict of interest** The authors declare no conflict of interest. The founding sponsors had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, and in the decision to publish the results.

## References

1. World Bank (2017) Percentage of fossil fuel energy consumed by countries. <http://datos.bancomundial.org/indicador/EG.USE.COMM.FO.ZS>. Last visit: 22th November, 2017
2. Endesa (2017) Anual report, sustainability. <https://www.endesa.com/content/dam/enel-es/home/inversores/infoeconomicafinanciera/informesanuales/documentos/2013/Sostenibilidad%202013.pdf>. Last visit: 22th November, 2017
3. Twenergy (2017) An Endesa initiative for efficiency and sustainability. <https://twenergy.com/a/el-largo-viaje-de-la-electricidad-211>. Last visit: 22th November, 2017
4. Brede M, de Vries BJM (2013) The energy transition in a climate-constrained world: regional versus global optimization. Environ Modell Softw 44:44–61. ISSN 1364-8152. <https://doi.org/10.1016/j.envsoft.2012.07.011>, <http://www.sciencedirect.com/science/article/pii/S1364815212002095>
5. del Viento G (2017) Wind-hydro-pumped station of El Hierro. <http://www.goronadelviento.es/index.php>. Last visit: 22th November, 2017
6. Ellouz IK, Ben Jmaa Derbel H, Kanoun O (2009) Temperature prediction of soil-pipe-air heat exchanger using neural networks. In: 6th International multi-conference on systems, signals and devices. SSD '09, pp 1–6. <https://doi.org/10.1109/ssd.2009.4956716>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4956638&isnumber=4956638>
7. Fan S, Methaprayoon K, Lee WJ (2010) Multi-region load forecasting considering alternative meteorological predictions. In: Power and energy society general meeting, 2010 IEEE, pp 1–7. <https://doi.org/10.1109/pes.2010.5589869>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5589869&isnumber=5588047>
8. Rastogi A, Srivastava A, Srivastava VK, Pandey AK (2011) Pattern analysis approach for prediction using wavelet neural networks. In: 2011 Seventh international conference on natural computation (ICNC), pp 695–699. <https://doi.org/10.1109/icnc.2011.6022288>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6022288&isnumber=6022138>
9. Chen X, Xu A (2011) Temperature and humidity of air in mine roadways prediction based on BP neural network. In: 2011 International conference on multimedia technology (ICMT), pp 1273–1276 <https://doi.org/10.1109/icmt.2011.6002598>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6002598&isnumber=6001647>
10. Routh TK, Bin Yousuf AH, Hossain MN, Asasuzzaman MM, Hossain MI, Husnaeen U, Mubarak M (2012) Artificial neural network based temperature prediction and its impact on solar cell. In: 2012 International conference on informatics, electronics & vision (ICIEV), pp 897–902. <https://doi.org/10.1109/iciev.2012.6317369>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6317369&isnumber=6317321>
11. Huang H, Chen L, Mohammadzaheri M, Hu E, Chen M (2013) Multi-zone temperature prediction in a commercial building using artificial neural network model. In: 2013 10th IEEE international conference on control and automation (ICCA), pp 1896–1901. <https://doi.org/10.1109/icca.2013.6565010>, <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6565010&isnumber=6564841>
12. Li X, Liu Y, Xin W (2009) Wind speed prediction based on genetic neural network. In: 4th IEEE conference on industrial electronics and applications. ICIEA 2009, pp 2448–2451
13. Zhao P, Xia J, Dai Y, He J (2010) Wind speed prediction using support vector regression. In: The 5th IEEE conference on industrial electronics and applications (ICIEA), pp 882–886
14. Tarade RS, Katti PK (2011) A comparative analysis for wind speed prediction. In: 2011 International conference on energy, automation, and signal (ICEAS), pp 1–6
15. Bhaskar K, Singh SN (2012) AWNN-assisted wind power forecasting using feed-forward neural network. IEEE Trans Sustain Energy 3(2):306–315
16. Nan S, Su-quan Z, Xian-hui Z, Xun-wen S, Xiao-yan Z (2013) Wind speed forecasting based on grey predictor and genetic neural network models. In: International conference on measurement, information and control (ICMIC), vol 02, pp 1479–1482
17. Chen N, Qian Z, Nabney IT, Meng X (2014) Wind power forecasts using gaussian processes and numerical weather prediction. IEEE Trans Power Syst 29(2):656–665
18. Ruffing SM, Venayagamoorthy GK (2009) Short to medium range time series prediction of solar irradiance using an echo state network. In: 15th International conference on intelligent system applications to power systems. ISAP '09, pp 1–6
19. Naing LP, Srinivasan D (2010) Estimation of solar power generating capacity. In: IEEE 11th international conference on probabilistic methods applied to power systems (PMAPS), pp 95–100
20. Wang J, Xie Y, Zhu C, Xu X (2011) Daily solar radiation prediction based on genetic algorithm optimization of wavelet neural network. In: International conference on electrical and control engineering (ICECE), pp 602–605
21. Ji W, Chee KC (2011) Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN. In: Solar energy vol 85(5), pp 808–817. <https://www.sciencedirect.com/science/article/pii/S0038092X11000259>. July 14, 2014
22. Salcedo-Sanz S, Casanova-Mateo C, Muñoz-Mari J, Camps-Valls G (2014) Prediction of daily global solar irradiation using temporal gaussian processes. IEEE Geosci Remote Sens Lett 11(11):1936–1940
23. Baptista D, Abreu S, Travieso-González C, Morgado-Dias F (2016) Hardware implementation of an artificial neural network model to predict the energy production of a photovoltaic system. Microprocess Microsyst 49:77–86. <https://doi.org/10.1016/j.micpro.2016.11.003>
24. Hernández-Travieso JG, Herrera-Jiménez AL, Travieso-González CM, Morgado-Días F, Alonso-Hernández JB, Ravelo-García AG (2017) Sustainability. vol 9, p 193. <http://www.mdpi.com/2071-1050/9/2/193>
25. Haykin S (1999) Neural networks. A comprehensive foundation, 2nd edn. Prentice Hall International, Inc., Upper Saddle River
26. Li X, Zecchin AC, Maier HR (2014) Selection of smoothing parameter estimators for general regression neural networks—applications to hydrological and water resources modelling. Environ Modell Softw 59:162–186. ISSN 1364-8152. <https://doi.org/10.1016/j.envsoft.2014.05.010>, <http://www.sciencedirect.com/science/article/pii/S1364815214001418>
27. Bakker M, Vreeburg JHG, van Schagen KM, Rietveld LC (2013) A fully adaptive forecasting model for short-term drinking water demand. Environ Modell Softw 48:141–151. ISSN 1364-8152. <https://doi.org/10.1016/j.envsoft.2013.06.012>, <http://www.sciencedirect.com/science/article/pii/S1364815213001576>
28. Valverde MC, Araujo E, Velho HC (2014) Neural network and fuzzy logic statistical downscaling of atmospheric circulation-type specific weather pattern for rainfall forecasting. Appl Soft Comput 22:681–694, ISSN 1568-4946. <https://doi.org/10.1016/j.asoc.2014.02.025>, <http://www.sciencedirect.com/science/article/pii/S1568494614000957>

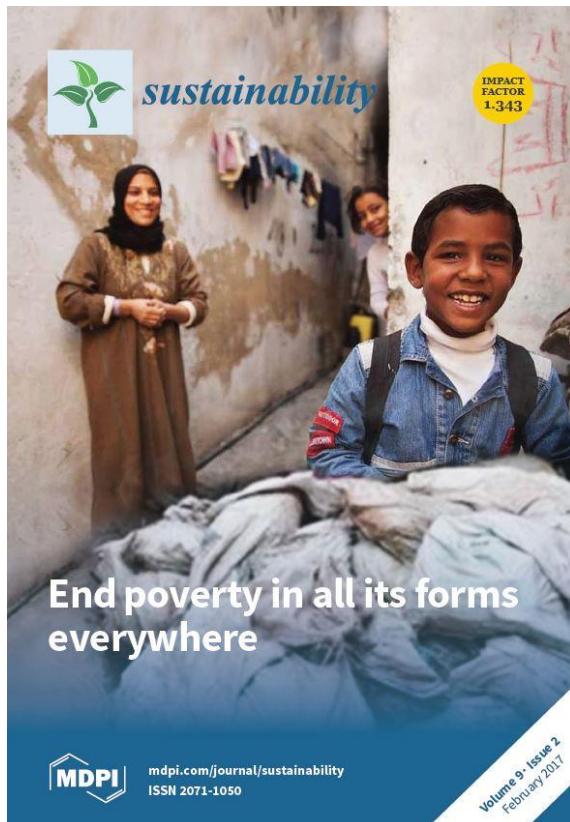
Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development

**Revista:** Sustainability.

**JCR 2017:** IF: 2.075, 21/33, Q3 (Green & Sustainable Science & Technology),  
120/241, Q3 (Environmental Science).

**Publicación online:** 28 de enero de 2017.

**URL:** <http://www.mdpi.com/2071-1050/9/2/193>



**Article**  
**Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development**

José Gustavo Hernández-Travieso<sup>1,\*</sup>, Antonio L. Herrera-Jiménez<sup>1</sup>,  
Carlos M. Travieso-González<sup>1</sup>, Fernando Morgado-Díaz<sup>2</sup>, Jesús B. Alonso-Hernández<sup>1</sup>  
and Antonio C. Ravelo-García<sup>1</sup>

<sup>1</sup> Signal and Communications Department, Institute for Technological Development and Innovation in Communications (IDETIC), University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, 35017 Las Palmas de Gran Canaria, Spain; antonio.herrera10@alu.ulpgc.es (A.L.H.-J.); carlos.travieso@ulpgc.es (C.M.T.-G.); jesus.alonso@ulpgc.es (J.B.A.-H.); antonio.ravelo@ulpgc.es (A.C.R.-G.)

<sup>2</sup> Madeira Interactive Technologies Institute, University of Madeira, 9000-105 Funchal, Portugal; morgado@uma.pt

\* Correspondence: jose.hernandez149@alu.ulpgc.es; Tel.: +34-928-499-965

Academic Editor: Vincenzo Torretta  
Received: 26 December 2016; Accepted: 25 January 2017; Published: 28 January 2017

**Abstract** Temperature control and its prediction has turned into a research challenge for the knowledge of the planet and its effects on different human activities and this will assure, in conjunction with energy efficiency, a sustainable development reducing CO<sub>2</sub> emissions and fuel consumption. This work tries to offer a practical solution to temperature forecast and control, which has been traditionally carried out by specialized institutes. For the accomplishment of temperature estimation, a score fusion block based on Artificial Neural Networks was used. The dataset is composed by data from a meteorological station, using 20,000 temperature values and 10,000 samples of several meteorological parameters. Thus, the complexity of the traditional forecasting models is resolved. As a result, a practical system has been obtained, reaching a mean squared error of 0.136 °C for short period of time prediction and 5 °C for large period of time prediction.

**Keywords:** temperature forecasting; sustainable development; artificial neural network; score fusion; prediction system

**1. Introduction**

Modern societies are conditioned by many natural factors, such as, for example, the weather. These changes not only have influence over the fields which are more directly connected with climatology, as the agricultural sector, but also over others which are more complex and apparently dissociated from atmospheric reality, as energy efficiency, and this becomes in an important factor in planning for sustainable urban development.

In fact, the climate is an important factor that affects the economy. It is especially important, not only in areas based on systems of agricultural production (such as developing countries) but also in other areas technologically developed and whose economies are based on other sectors such as tourism, or even in those that try to approach a sustainable economy through renewable energy sources [1]. Prediction is, therefore, a tool to be modelled and developed that can be compared to different procedures from each specific area. There are currently three important trends which tackle this theme: Climatology, acting as empirical tradition; Physics of the Atmosphere, as theoretical tradition; or Numerical Weather Prediction (NWP), as modern tradition [2]. These recent mathematical models struggle at present to achieve a shorter response time as main target. However, the more accurate the method is, the more data is required and therefore a longer response time is obtained.

*Sustainability* 2017, 9, 193; doi:10.3390/su9020193

[www.mdpi.com/journal/sustainability](http://www.mdpi.com/journal/sustainability)



Article

# Temperature Control by Its Forecasting Applying Score Fusion for Sustainable Development

José Gustavo Hernández-Travieso <sup>1,\*</sup>, Antonio L. Herrera-Jiménez <sup>1</sup>,  
Carlos M. Travieso-González <sup>1</sup>, Fernando Morgado-Dias <sup>2</sup>, Jesús B. Alonso-Hernández <sup>1</sup>  
and Antonio G. Ravelo-García <sup>1</sup>

- <sup>1</sup> Signal and Communications Department, Institute for Technological Development and Innovation in Communications (IDeTIC), University of Las Palmas de Gran Canaria, Campus Universitario de Tafira, 35017 Las Palmas de Gran Canaria, Spain; antonio.herrera101@alu.ulpgc.es (A.L.H.-J.); carlos.travieso@ulpgc.es (C.M.T.-G.); jesus.alonso@ulpgc.es (J.B.A.-H.); antonio.ravelo@ulpgc.es (A.G.R.-G.)
- <sup>2</sup> Madeira Interactive Technologies Institute, University of Madeira, 9020-105 Funchal, Portugal; morgado@uma.pt

\* Correspondence: jose.hernandez149@alu.ulpgc.es; Tel.: +34-928-459-965

Academic Editor: Vincenzo Torretta

Received: 26 December 2016; Accepted: 25 January 2017; Published: 28 January 2017

**Abstract:** Temperature control and its prediction has turned into a research challenge for the knowledge of the planet and its effects on different human activities and this will assure, in conjunction with energy efficiency, a sustainable development reducing CO<sub>2</sub> emissions and fuel consumption. This work tries to offer a practical solution to temperature forecast and control, which has been traditionally carried out by specialized institutes. For the accomplishment of temperature estimation, a score fusion block based on Artificial Neural Networks was used. The dataset is composed by data from a meteorological station, using 20,000 temperature values and 10,000 samples of several meteorological parameters. Thus, the complexity of the traditional forecasting models is resolved. As a result, a practical system has been obtained, reaching a mean squared error of 0.136 °C for short period of time prediction and 5 °C for large period of time prediction.

**Keywords:** temperature forecasting; sustainable development; artificial neural network; score fusion; prediction system

---

## 1. Introduction

Modern societies are conditioned by many natural factors, such as, for example, the weather. The meteorological changes affect to different aspects of our lives. These changes not only have influence over the fields which are more directly connected with climatology, as the agricultural sector, but also over others which are more complex and apparently dissociated from atmospheric reality, as energy efficiency, and this becomes in an important factor in planning for sustainable urban development.

In fact, the climate is an important factor that affects the economy. It is especially important, not only in areas based on systems of agricultural production (such as developing countries) but also in other areas technologically developed and whose economies are based on other sectors such as tourism, or even in those that try to approach a sustainable economy through renewable energy sources [1]. Prediction is, therefore, a tool to be modelled and developed that can be compared to different procedures from each specific area. There are currently three important trends which tackle this theme: Climatology, acting as empirical tradition; Physics of the Atmosphere, as theoretical tradition; or Numerical Weather Prediction (NWP), as modern tradition [2]. These recent mathematical models struggle at present to achieve a shorter response time as main target. However, the more accurate the method is, the more data is required and therefore a longer response time is obtained.

Meteorological services hold that the solution to that problem lies in the development of traditional computing algorithms but in fact, there are emerging alternatives focused on the future of weather forecast, such as Artificial Neural Networks (ANN) with supervised learning. Temperature prediction through time series is an important technique, in which past observations of certain weather variables are collected and analyzed to develop a model based on the underlying relationship between them. It is important to have in mind that any temperature modeling is a chaotic system in which small errors in the initial prediction conditions grow very quickly and affect the predictability [3].

Mathematical models based on linear methods have been used for prediction of time series but the appearance of Artificial Neural Networks have offered a possibility to set new methodologies. These ANN models are at present acquiring a great relevance for the recognition of patterns and even for the biometrics. In the last decades some related works on meteorology have been developed, for example, in an approach to the coexistence of these models, G. Peter Zhang [4] proposed in 2001 a hybrid system using the linear method ARIMA (Auto Regressive Integrated Moving Average) and ANNs at the same time. In this study, it was concluded that the nonlinear model of ANN offers results which are slightly more favorable against the complexity of the linear system, because the most important advantage of ANN is their flexible nonlinear modeling potential.

In the field of meteorology, ANNs are also being used for prediction of atmospheric phenomena and its application to power generation systems. In 2007, Sorjamaa, Hao, Reyhani, Ji and Lendasse [5] proposed a global methodology for the long-term prediction of time series, combining direct prediction strategy and sophisticated input selection criteria. This methodology was successfully applied to the Poland Electricity Load dataset.

In 2009, Ellouz, Ben-Jmaa-Derbel and Kanoun [6] used ANNs to propose a tool to be able to evaluate aspects of the heat interchange between land and air through underground pipes in order to achieve improvements in weather conditions of the building, with a prediction error between the predicted and the experimental outlet temperature of 1.1 °C from 8 pm to 8 am and an error lower than 4 °C from 10 am to 5 pm. A year later, Fan, Methaprayoon and Lee [7] made overload forecasting considering meteorological predictions. The results were very positive and it helped to improve the energy efficiency of the power station at precise times of higher electricity demand, obtaining an error of 2 °C. In 2011, Rastogi, Srivastava, Srivastava and Pandey [8] used patterns analysis with ANNs for temperature forecasting. With those results, the efficiency of the proposed model was demonstrated with a high accuracy between actual values and predicted values. In the same year, Chen and Xu [9] implemented a model based on ANNs for the prediction of temperature and humidity roadways of coal mines. The results had an error range, which was within the limits fixed (0.2% to 4.9%). Afterwards, in Bangladesh (2012), Routh, Bin Yousuf, Hossain, Asasuzzaman, Hossain, Husnaeen and Mubarak [10] also performed temperature predictions using models based on ANNs to improve energy efficiency in solar power stations. In this last case the results were also favorable. A little later (2013), Huang, Chen, Mohammadzaheri, Hu and Chen [11] also used these models to make a multi-zone temperature prediction in the terminal building of the airport of Australia, where the results achieved a prediction error of just 1 °C.

Taking into account the diversity and progress in prediction strategies for multi-step ahead prediction, Ben Taieb, Bontempi, Atiya and Sorjamaa [12] made in 2012 a review of the different existing strategies for multi-step ahead forecasting and made a comparison between them, in theoretical and practical terms. As a conclusion they observed that the complexity of making a forecast of time series many steps into the future is high due to the uncertainty, which increases with a larger time horizon.

Using data from the same meteorological stations of this research, Vásquez, Travieso, Pérez, Alonso y Briceño [13] presented a system that reaches an error of 0.28 °C making temperature predictions using multilayer ANN.

In 2013, Xiong, Bao and Hu [14] proposed a revised hybrid model built upon empirical mode decomposition based on the feed-forward neural network modeling framework incorporating the slope based method. The model was applied to obtain a prediction of crude oil prices, obtaining great

accuracy. In 2014, Hernández-Travieso, Travieso and Alonso [15] also used ANNs to predict wind speed using data from meteorological stations situated in Gran Canaria and Tenerife (Canary Islands, Spain). In this work, ANN proved to be a powerful tool to make an accurate prediction obtaining a mean absolute error (MAE) of 0.85 meters per second. In 2014, Bao, Xiong and Hu [16] proposed a particle swarm optimization based multiple-input several multiple-outputs (PSO-MISMO) modeling strategy, having the capability to determine the number of sub-models in a self-adaptive mode, with variable predictions. The strategy has been validated with simulated and real datasets. In 2015, Li, Qin, Ma and Wu [17] used ANN to make a prediction of greenhouse inside temperature in the typical summer climate in China, reaching a mean square error of 0.01 °C. In addition, in 2015, McKinney, Pallipuram, Vargas, Taufer [18], made a research to study extreme climate events, and unusually high and low temperatures were studied on it. They reach results of more than 90% hits. In 2016, Prashanthi, Meganathan, Krishnan, Varahasamy, Swaminathan [19] proposed a model that finds the extreme hot day prediction 24 and 48 h ahead with the help of local weather parameters.

The importance of temperature and sea level rise is shown by Aral and Guan [20] in 2016, where the impact of sea surface temperature and sea levels in previous years is included on current sea level rise. There is a relationship between temperature and sea level rise. The same conclusion was reached by Arora and Dash [21] in 2016, the sea-air temperature contrast also contributes to fuels tropical cyclone systems increasing its destructive power.

All there are examples that highlights the importance of an accurate temperature prediction, not only to reduce CO<sub>2</sub> emissions, which is especially important in urban areas, but also to serve as a tool to aid emergency systems in order to be able to be one step ahead of natural disasters.

Therefore, although temperature forecasting is a very complex and imprecise science, these studies have shown that ANNs have a powerful capability of classification and pattern recognition and can be used as tools to achieve accurate predictions in the field of meteorology [22].

In this research, four contributions or innovations versus the state-of-the-art are proposed. First of all, the feedback topology was used to study different configurations, in order to determine how the behavior of this architecture for using in temperature forecasting is. Secondly, a combined input-stimulus with information from other meteorological parameters, which directly affect daily cycles of temperature, is presented. Thirdly, an optimization based on a score fusion method has been introduced to evaluate heuristically whether it improves the degree of forecasting of this proposal. Finally, a standardization of input-data in the system was also established, that will impact positively during the training phase.

In this research, a system based in a backpropagation-ANN using Score Fusion is proposed for temperature forecast. To do this, information from real meteorological stations is taken for the prediction. The model will be tested using non-feedback topology to get immediate predictions but also using feedback topology to obtain long-term predictions. This last distinguishing aspect will make it possible to reach new contributions to the scientific community since ANNs that respond in a feedback architecture, have not been previously studied in detail. The flow chart of Figure 1 summarizes the main steps developed in the proposed model.



**Figure 1.** Blocks sequence for the temperature system.

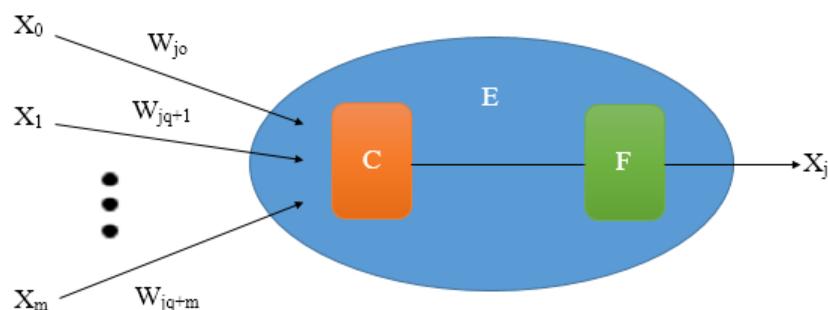
The remainder of this paper is as follows. In Section 2, theoretical aspects of the backpropagation ANNs using Score Fusion will be briefly discussed, as well as the decisions which have been taken in the design of this proposed model. Afterwards, the results obtained during the different experiments will be exposed in Section 3. Section 4 presents the discussion of the results obtained and the comparison with previous works. Finally, in Section 5, the conclusions of this research will be presented.

## 2. Materials and Methods

After studying previous works for time series forecasting in the state-of-the-art, a backpropagation topology has been used for the development and implementation of this research, showing an improvement versus the ANN model only when Score Fusion is used. Models based in backpropagation-ANN [4] are the most appropriate architecture to estimate future values from training with time series against any other topologies or even against conventional linear methods, due to the adaptability of the system.

Artificial Neural Networks are an information processing paradigm which is inspired by the biological nervous systems. The key element of this paradigm is the new structure of the information processing system. It is composed of a large number of highly interconnected processing elements (neurons), working together to solve specific problems. A neural network is a powerful data modeling tool that is able to capture and represent complex input-output relationships [23]. One of its types, Multilayer ANN, is a network consisting of multiple layers of action and for the proposed model it will consist of three layers. The first one, input layer, receives information from external sources. The second one, hidden layer, is responsible for running the internal processes of the network. The third one, performance or output layer is responsible for communicating the response of the system to the outside.

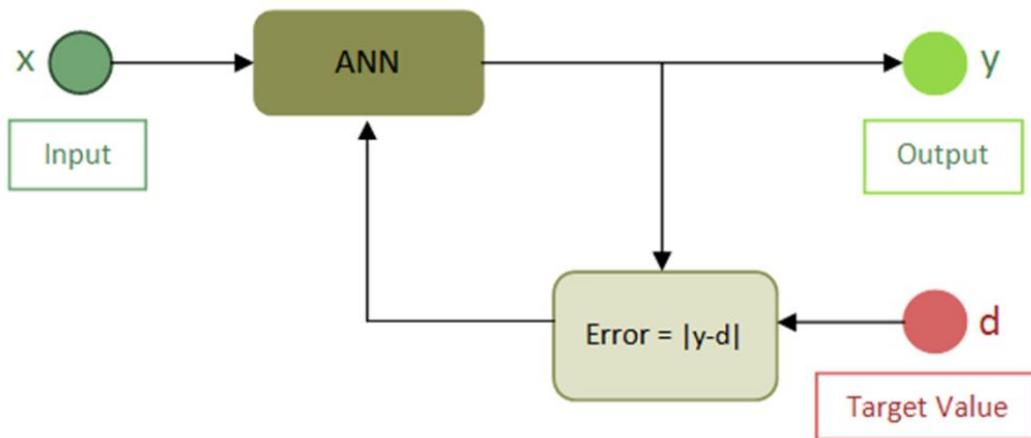
Each one of these layers is comprised of elementary processing units which are called artificial neurons. Each neuron has individually a certain number of entries, a processing node and a single output and each connection between neurons is associated with a weight value [24]. ANNs are able to model the relationship between inputs and outputs by modifying the weight values of the connections. Therefore, an ANN is configured for a particular application, such as pattern recognition or data classification, through a learning process. For this research, the Backpropagation Method was used, which is characterized by a supervised learning type. A diagram of an artificial neuron is shown on Figure 2; where  $W_{ji}$  is the weight associated to each input- $X_i$  of the  $j$ -neuron. In addition, this neuron is formed by a combination function C (which adds input-signals), an Operational Element E (associated to the weight value) and an Activation Function F.



**Figure 2.** Diagram of an artificial neuron.

Backpropagation is commonly used as a training method in conjunction with an optimization approach such as gradient descent (based on Steepest Descent method) and it shows results closed to real values ( $MAE = 0.136 \text{ }^{\circ}\text{C}$  for predictions within hours). This method calculates the gradient of a loss function according to all the weights in the network. The resulted gradient is fed back to the optimization method which, in turns, uses it to update the weights in an attempt to minimize the loss function. This Backpropagation algorithm is made up of two phases: a forward phase and a backward phase. In the forward phase, the activations are propagated from the input (x) to the output layer. In the backward phase, the error between the observed actual value (target d) and the requested nominal value (y) in the output layer is propagated backwards in order to modify the internal weight values ( $W_{ji}$ ) of the network, as shown in Figure 3. It is important to note that, generally, the initialization of these weight values ( $W_{ji}$ ) has been done randomly. Once the ANN reaches the

training convergence, the experiment proceeds to the next stage for prediction where the Score Fusion module was applied.



**Figure 3.** Diagram of the Backpropagation model in the backward phase.

To perform this proposed method, a database from a village in the Republic of Costa Rica has been used. This locality, called Turrialba, is an interesting place characterized by a climate of contrasts. Turrialba is surrounded by a river and emplaced on slopes of a currently active volcano which affects directly the climate of the area.

The original database for this research is presented in Excel format, containing various meteorological variables such as temperature, humidity, atmospheric pressure, wind speed, etc. The data was obtained between July 2007 and September 2008 and presents a sampling frequency of 30 min. This last aspect is very important to note because the use of lower sampling frequencies could generate unfavorable results in future works.

At the preprocessing stage, to choose the elements involved in combined input-stimulus, the most influential meteorological elements on daily cycles of temperature have been studied. Depending on the limitations of meteorological database, solar radiation, leaf wetness and time of sample acquisition have been chosen [25,26]; where “leaf wetness” is the quantity of condensed water-vapor on the plant leaves. It indicates the humidity and measures the electrical resistance which the plant has from the humid environment. When the relative humidity is high, the electrical resistance is low, and the leaf wetness is low. The “time of sample acquisition” value refers to the time when the meteorological station acquires the meteorological parameter. Later, normalization of input-data values between  $(-1, 1)$  was established in order to solve two problems. Firstly, data dispersion presented by working with parameters from different scales of measurement is clearly reduced. Secondly, the range of values taken by the weight values of neurons is bounded, achieving a faster and more stable convergence during the training phase.

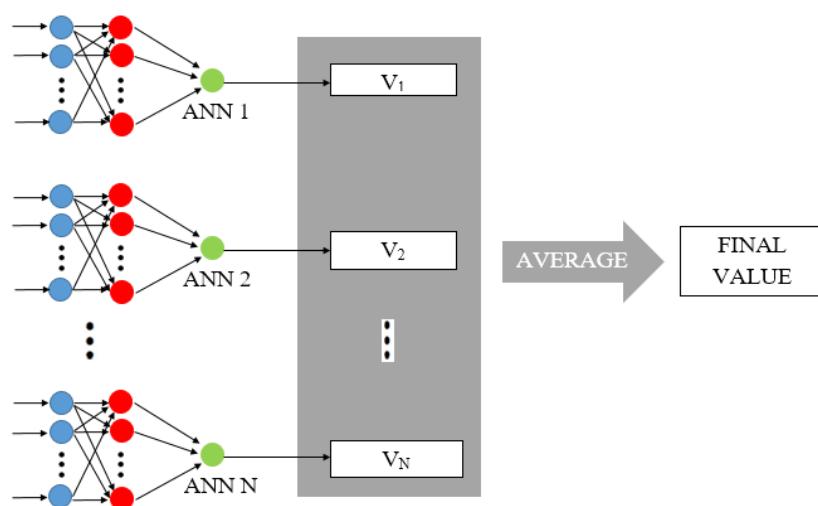
Regarding the configuration of the proposed system, it is set based on three parameters. Firstly, the window length, which represents the sliding window in time to capture values from the database, determines the number of neurons in the input layer. This sliding window represents the number of past values needed to obtain a temperature prediction. Secondly, the number of neurons in the hidden layer, which defines the number of fixed neurons for the middle layer and finally, the number of training patterns, which represents the quantity of examples offered to the ANN for the training stage. Thirdly, different settings will be established with the benchmarks to study the response of the model.

It offers two clearly differentiated working modes. The first one will be characterized by a non-feedback topology to get values of immediate prediction, where each sliding window formed by real values will estimate a single value of temperature. The second one will be characterized by a

feedback topology to get short-term predictions, where, from a single window, a continuous prediction in time will run using estimated values to generate new temperature values.

The last step of our process, Score Fusion, specifically the technique of Adding-Score has been introduced to evaluate whether or not it is effective in improving the degree of forecast for the proposed model. In this case, a backpropagation architecture that generates a random initialization of weight values is used. This fact causes that two ANNs, which have been equally configured and trained with the same training patterns; generate different responses due to the random initialization of the ANN weights. These responses are very similar, but not exactly the same. In this way, the optimization method is conceived as a neural structure consisting of several identical ANNs working in parallel. The overall response, represented by Equation (1), corresponds to the calculation of the average value of all the ANNs (see Figure 4).

$$\text{Final Value} = \frac{1}{N} \sum_{i=1}^N V_i \quad (1)$$



**Figure 4.** Score-Fusion block for a number of “N” ANN.

Since the ANN is modelled to maximize the success rate, this ANN is applied multiple times in parallel using random initialization. As shown in Figure 4, Adding-Score is formed by a set of “N” ANN in parallel and where the final value is calculated as the average of responses of each ANN.

Independently of this topology, the system will be stimulated with observations of different nature. On the one hand, it will be stimulated by only temperature values to get estimations of this variable. On the other hand, a combined input-stimulus with other meteorological elements will be used together with the temperature data to get predicted temperature values, so it can be studied whether using multiple input-information which improves the level of each prediction. In this way, four different working modes can be well defined. For an easy explanation of results achieved during the stage of experimentation, the following nomenclature has been proposed to define each mode in Table 1.

**Table 1.** Working modes and their definition.

Working Mode	Single Input-Stimulus	Combined Input-Stimulus
Non-feedback topology (Immediate Prediction)	MODE.1	MODE.2
Feedback topology (Short-Term Prediction)	MODE.3	MODE.4; MODE.4v2

For modes that make use of temperature values (Mode.1 and Mode.3), a dataset of 20,000 samples have been used, whereas for the others (Mode.2, Mode.4 and Mode.4v2) a dataset of 10,000 samples

was selected. The difference in the number of samples is due to the fact that the best results are obtained with these parameters. The difference between Mode.4 and Mode.4v2 is that in Mode.4v2 the sampling time parameter is also used in the prediction.

Regarding the evaluation of error parameters, two goodness criteria have been established according to both topologies. Thus, for the non-feedback topology, mean absolute error (MAE) parameter was proposed as an indicator for a dataset of estimated values whereas for the feedback topology, it was set up mainly the accumulated error parameter, which determines the evolution of the absolute error for each new estimated temperature value and it is defined as the absolute error of the use of estimated samples to estimate future predictions (estimated samples for a feedback mode).

In order to improve the efficiency of our classification system, a Score Fusion module was applied. The goal of this module was to reduce the effect introduced by the random initial of the weights used in the neural networks. Using “N” neural networks, obtaining “N” different solutions for the same input data. The idea was to amalgamate the “N” outputs in order to generalize the output to the results of neural networks that perform better.

Score Fusion is the name used to refer to the different mathematical methods for obtaining a better result once the experiment is done. That means that, when the ANN shows its results, it is possible to improve with some mathematical operations. In our case, the Score Fusion technique used is Adding-Score. This specific technique is based on the addition of mono-modal scores reached by each ANN during the experiment. This fusion block is applied based on the random initialization of weights and different convergences reached each time that an ANN is executed. Therefore, to establish a generalization, but always applying the same input data [27], “N” ANN are executed and theirs outputs are fused using Adding-Score.

### 3. Results

In this section, once the experiments described in Table 1 are realized, the best results for each mode of running are presented. They have been obtained by diverse benchmarks tests, in which the ANN has been subjected to different configurations by modifying the sliding window, the number of hidden neurons and the number of training patterns parameters. Moreover, an optimization based on Adding-Score approach has been applied for each optimal result in order to reduce the error rate of the proposed model.

For each of the modes described in Table 1, a set of configurations were used to experiment with overall simulations to determine the best results. After locating the best configurations, they have been again simulated in order to establish which configuration was more efficient. Subsequently, each parameter was varied with values close to the optimal configuration to see if new enhancements were achieved in the system response. Finally, some of the results, including the best results for each mode, as well as others that are representative, are presented in this paper.

#### 3.1. Mode.1

For Mode.1, the overall simulation was established with the combination of the parameter values showed in Table 2.

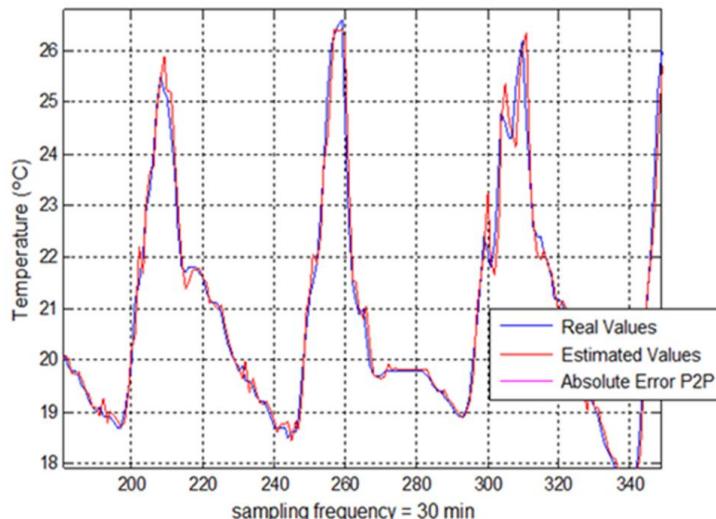
**Table 2.** Used parameter values for the overall simulation in Mode.1.

Type of Mode	Sliding Window Length	Hidden Neurons	Training Patterns
MODE.1	4, 5, 6, 12, 24, 36, 48	8, 12, 16, 24, 32, 64	1000, 3000, 5000, 8000

Table 3 presents the selected best result for Mode.1. It has been obtained for the described configuration where the MAE rate did not exceed the value of 0.2639 °C for a dataset of 1000 simulated samples. In Figure 5, can be also seen how estimates generated by the system are closely suited to the daily cycles of real temperature.

**Table 3.** Best result in Mode.1.

<b>Setting</b>	<b>Sliding Window Length</b>	4
	<b>Hidden Neurons</b>	12
	<b>Training Patterns</b>	3000
Mean Absolute Error	0.2639 °C	
Mean Squared Error	0.1659 °C	
Training Time	35.33 s	
Simulation times	$3.96 \times 10^{-2}$ s	

**Figure 5.** Graph of best result in Mode.1.

After executing the Adding-Score, it has been verified that this optimization slightly improves the degree of forecast but only for a few hundredths of Celsius degree. For this reason, the results will be indicated with four decimals in the followings tables. Thus, it is important to evaluate whether this improvement reaches the required needs for the intended purpose. Tables 4 and 5 shows the results obtained for MAE and various settings of the Adding-Score method running in Mode.1, where N represents the number of ANNs in parallel used on several benchmarks test varying it in order to obtain best results (when N = 1, the first random ANN was used).

**Table 4.** Results obtained for different numbers of ANNs in parallel for Adding-Score (Mode.1 Test1).

<b>Adding-Score (Mode.1 Test1)</b>	<b>N = 1</b>	<b>N = 5</b>	<b>N = 10</b>	<b>N = 15</b>
MAE (°C)	0.2770	0.2701	0.2681	0.2692

N represents the number of ANNs in parallel used on several benchmarks test.

**Table 5.** Results obtained for different numbers of ANNs in parallel for Adding-Score (Mode.1 Test5).

<b>Adding-Score (Mode.1 Test5)</b>	<b>N = 1</b>	<b>N = 5</b>	<b>N = 10</b>	<b>N = 15</b>
MAE (°C)	0.3450	0.3361	0.3352	0.3340

N represents the number of ANNs in parallel used on several benchmarks test.

Although the improvement of 15 ANN with comparison to 1 ANN is marginal, our latency time is 1 h, so we have enough time to train again the system. This means that, it is not convenient to the execution with 15 ANN.

### 3.2. Mode.2

For Mode.2, the overall simulation was established with the combination of the parameters shown in Table 6.

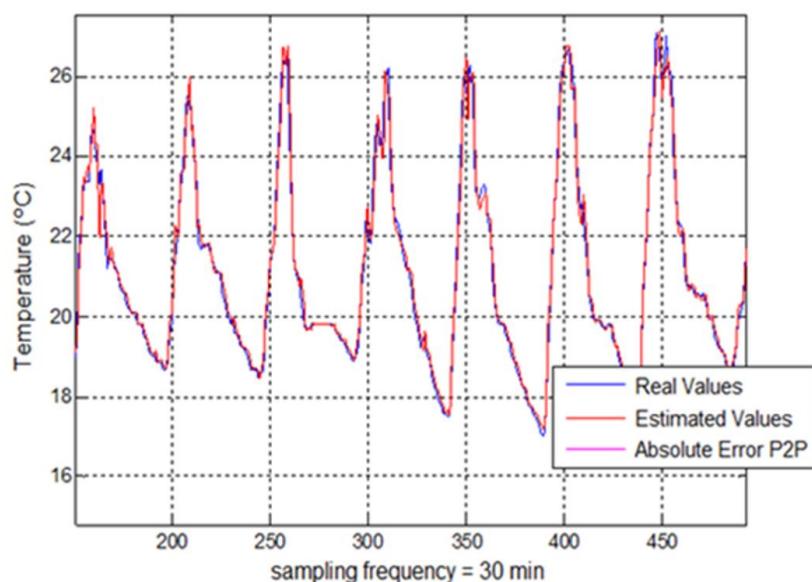
**Table 6.** Used parameter values for the overall simulation in Mode.2.

Type of Mode	Sliding Window Length	Hidden Neurons	Training Patterns
MODE.2	4, 6, 12, 24, 36, 48	8, 12, 16, 24, 32	1000, 3000, 4000, 5000

The best results for Mode.2 are shown in Table 7, where the MAE rate did not exceed the value of 0.2294 °C for a dataset of 1000 simulated samples. Therefore, it is confirmed that the use of combined input-stimulus improves the forecast reducing MAE by 15%, approximately, compared to Mode.1. Paying attention to Figure 6, it can be equally noticed how generated estimates are also closely suited to the daily cycles of real temperature. Moreover, it is important to note how the number of required hidden neurons is lower than in the previous mode.

**Table 7.** Best result in Mode.2.

Setting	Sliding Window Length	4
	Hidden Neurons	8
	Training Patterns	4000
Mean Absolute Error	0.2294 °C	
Mean Squared Error	0.1359 °C	
Training Time	52.94 s	
Simulation times	$4.04 \times 10^{-2}$ s	



**Figure 6.** Graph of the best result in Mode.2.

As far as optimization based on Adding-Score approach is concerned, similar aspects are concluded for this mode. It is also interesting to note, once the experiments were carried out, how for systems which are composed of more than 5 ANNs, their responses are often worse than for a single ANN (see Tables 8 and 9). In this specific case, it is deduce that the errors are correlated between the different ANNs, and therefore cannot correct them. This is a particular case, since in general,

the Score-Fusion tends to improve the result. In this case, although the initialization of the neural network is random, it arrives at the same solution and therefore does not improve. Therefore, in case of implementing this method it is advisable to use only architectures composed of a number of ANNs between 3 and 5 to achieve favorable results, as seen in Tables 8 and 9.

**Table 8.** Results obtained for different numbers of ANNs in parallel for Adding-Score (Mode.2 Test1).

Adding-Score (Mode.2 Test1)	N = 1	N = 5	N = 10	N = 15
MAE (°C)	0.2804	0.2754	0.2857	0.2832

N represents the number of ANNs in parallel used on several benchmarks test.

**Table 9.** Results obtained for different numbers of ANNs in parallel for Adding-Score (Mode.2 Test3).

Adding-Score (Mode.2 Test3)	N = 1	N = 5	N = 10	N = 15
MAE (°C)	0.2956	0.2868	0.2878	0.2979

N represents the number of ANNs in parallel used on several benchmarks test.

### 3.3. Mode.3

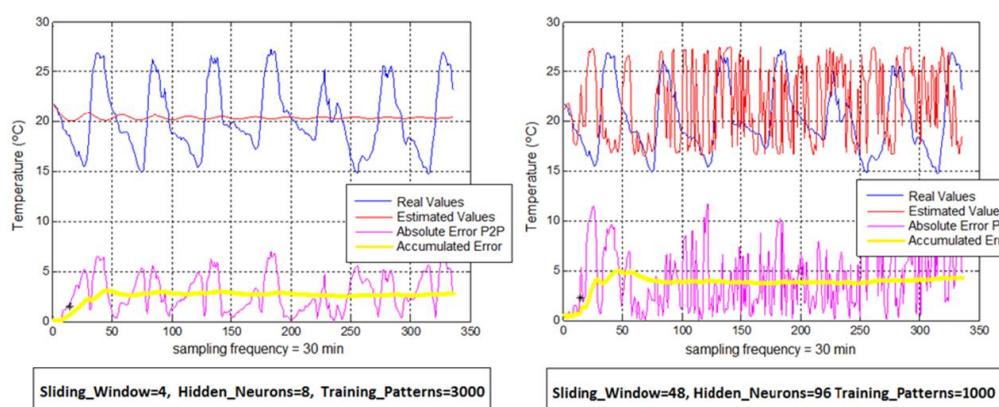
For Mode.3, two overall simulations were established separately to avoid overloading and long runtimes. Table 10 shows the combination of the parameter values.

**Table 10.** Used parameter values for both overall simulations in Mode.3.

Type of Mode	Sliding Window Length	Hidden Neurons	Training Patterns
MODE.3.A	4, 8, 12, 24, 48	6, 8, 12, 16, 24	1000, 3000, 4000, 5000
MODE.3.B	24, 48, 72, 96	12, 16	3000, 4000, 5000

Below, the results obtained for the feedback modes are presented. It is important to note that the parameters of goodness for these modes (accumulated error, threshold and standard error) were presented only as indicators of goodness but were not determinant. Therefore, heuristic studies have been applied to decide the best settings for each mode. This is because the accumulated error is not instantaneous. This error rate is the result of the actual error plus the obtained in previous steps. Due to this, the results of these feedback modes will be presented through graphs generated in the simulation.

As shown in the graphs of Figure 7, settings which were optimal for non-feedback modes are inadequate for short-term forecast because longer sliding windows are needed for prediction with longer time horizons. However, if the value of this parameter is too high, the response is chaotic since the system generates an unstable convergence during the training phase.

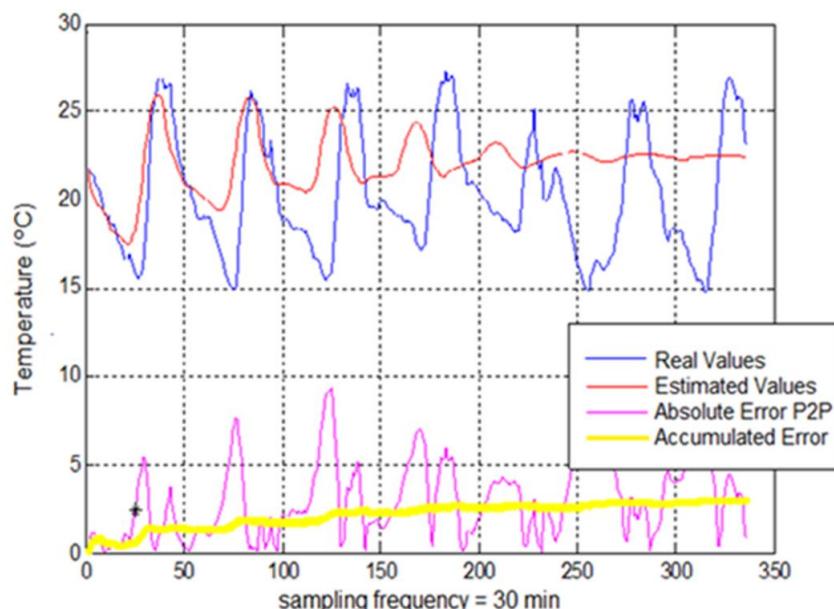


**Figure 7.** Graphs of some results obtained in Mode.3.

For Mode.3 it is important to know the prediction time in which the forecast is being established due to the fact that, for a longer timeframe, the precision of the first samples will be lower than those obtained for shorter ones. Finally, the best settings for this mode for a 24-hours-forecast are presented in Table 11 and Figure 8.

**Table 11.** Best result in Mode.3.

Setting	Sliding Window Length	24
	Hidden Neurons	12
	Training Patterns	4000
Mean Absolute Error	<1.50 °C	
Mean Squared Error	5.00 < $e$ < 5.40 °C	
Training Time	397.92 s	
Simulation times	33.74 s	



**Figure 8.** Graph of the best result in Mode.3.

For this simulation, the error is low and unstable at initial samples. When the number of samples is increased, this error becomes more stable and a little bit higher in previous samples (see yellow line in Figure 8). Regarding the optimization in this mode, similar conclusions are obtained. That is, the use of the Adding-Score method improves the curve of prediction for systems which do not exceed 5 ANNs in parallel. Furthermore, this optimization method would be better suited for the feedback modes since instability in the prediction of these modes is often presented.

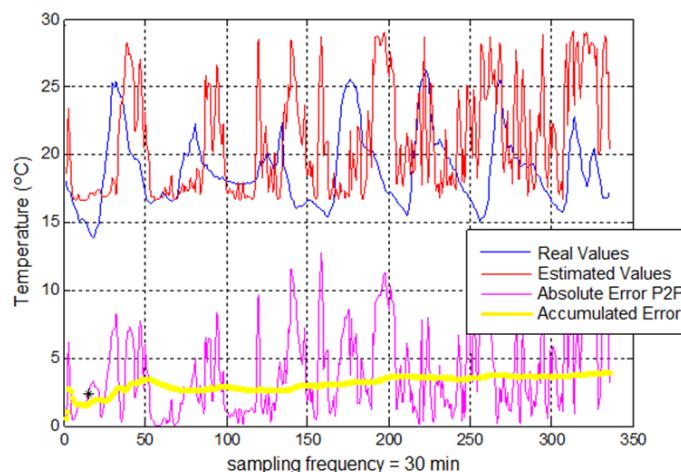
### 3.4. Mode.4

From the results of Mode.2, it was concluded that the feedback modes require larger values of sliding window length. The overall simulation was established for this case as Table 12 shows.

**Table 12.** Used parameter values for the overall simulation in Mode.4.

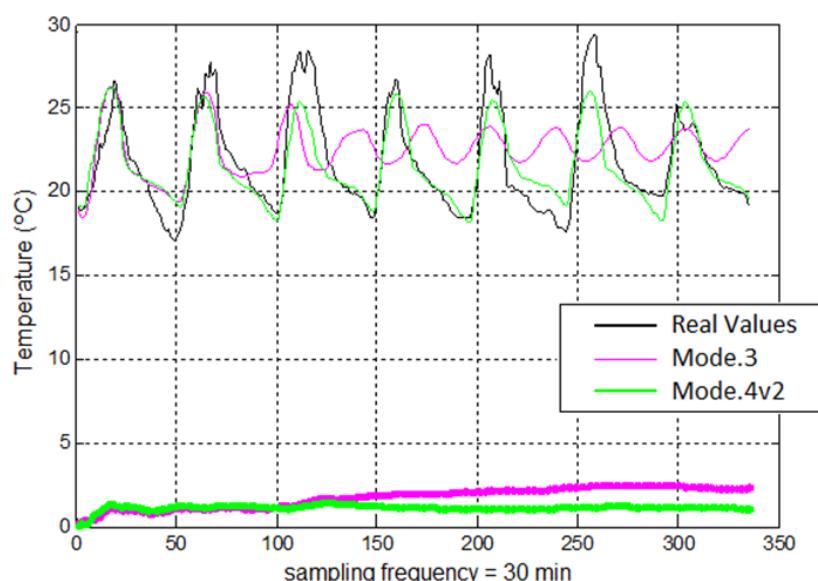
Type of Mode	Sliding Window Length	Hidden Neurons	Training Patterns
MODE.4	24, 48	10, 12, 16	3000, 4000

In non-feedback modes it was clearly demonstrated that the use of combined input-stimulus improved the prediction. However, conversely, in order to stimulate with this criterion (Mode.4) a prediction of each of the input individual elements is required. Thus, due to the error introduced by each element separately and the error introduced by the whole prediction, the system offers chaotic responses which produce a non-viable model. Figure 9 is an obvious example of this.



**Figure 9.** Representative graph of results in Mode.4.

To resolve that problem, it is necessary to use in Mode.4 any element combined with temperature which is not subjected to an inaccurate estimation. The solution can be finally found in the sampling time parameter, whose evolution can be known precisely, thus obtaining Mode.4v2. In addition, the use of this parameter facilitates the temperature estimates with further horizons time with respect to Mode.3. Figure 10 is a clear example of this improvement, where in Mode.4v2 the prediction reaches a longer-term, achieving a proper synchronization between real temperature cycles and estimated temperature cycles. However, for short periods of estimation (approximately the first 72 samples) Mode.3 gets a lower error rate. Thick lines of the lower part of Figure 10 represent the accumulated error from each mode. Due to this fact, the previous Mode.3 is recommended, in general terms, for predictions with a timeframe which is equal or less than twice the sliding window.



**Figure 10.** Comparative graph of results between Mode.3 and Mode.4v2.

### 3.5. Wilcoxon Signed Rank Test

In order to observe the statistical significance of the results comparison a Wilcoxon signed rank test [28,29] for the modes used in the present work has been applied and presented in Table 13. In the experiments, *p*-value is obtained with first 48 samples in all cases. After Inspection of Table 13 we can observe the good performance in Modes 1 and 2.

**Table 13.** Wilcoxon signed rank test for the modes used in the present work.

Type of Mode	Sliding Window	Hidden Neurons	Training Patterns	Sample Size for Wilcoxon Signed Rank Test	<i>p</i> -Value
MODE.1	4	12	3000	48	0.15
MODE.2	4	8	4000	48	0.16
MODE.3	4	8	3000	48	$2.86 \times 10^{-7}$
MODE.3	48	96	1000	48	$2.53 \times 10^{-5}$
MODE.3	24	12	4000	48	0.07
MODE.4	48	16	3000	48	0.0027

## 4. Discussion

After studying the behavior of the neural system through different working modes, some important conclusions have been obtained with regard to the methodologies to establish. It has been observed that an increase in the number of hidden neurons does not produce better results. This is because if a high number of neurons for a given input configuration are defined, the system becomes unstable and therefore, the required level of convergence stability is not achieved during the training.

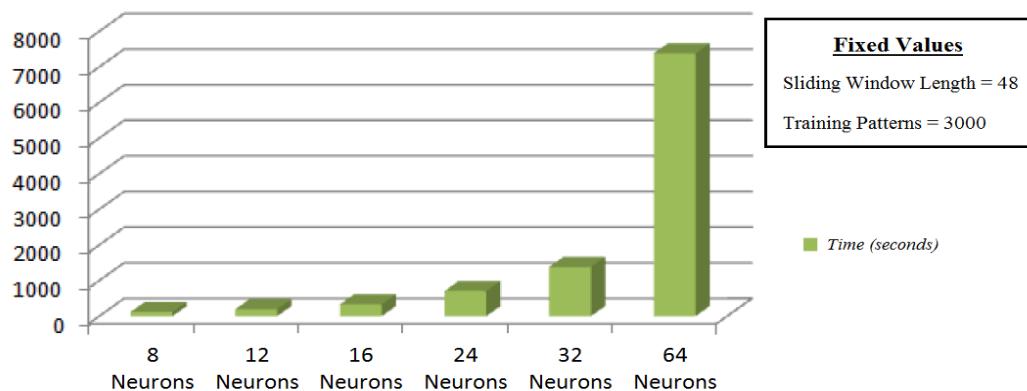
A random increase in the number of training patterns does not generate more accurate answers. This is because, after reaching the level of internal stability of the weight values of the ANN, the system becomes once again unstable if it keeps on offering new patterns. It is necessary therefore, to find a balance between the numbers of offered patterns against the number of inputs. This balance can only be known through heuristic procedures.

The study of training time is an important issue, being the latency between predictions, in particular, for short time predictions, a key aspect to reach a more accurate system. Moreover, it is necessary to add the test times, but it is insignificant compared to the training time. After the experiments, a key point is the number of hidden neurons, which is presented as the most influential parameter in the computational costs. This is because a linear increment in this parameter generates an exponential time increase in the phase of training as seen in Figures 11–13. However, this increase of the parameters hardly affects the estimation phase, where the prediction time is almost immediate and answers are obtained in order of 0.04 s for the non-feedback modes. This is due to the execution in parallel which characterizes this type of architecture. Therefore, the latency in the estimation phase depends on the time in which the meteorological station provides new stimuli to the system being 30 min in this work.

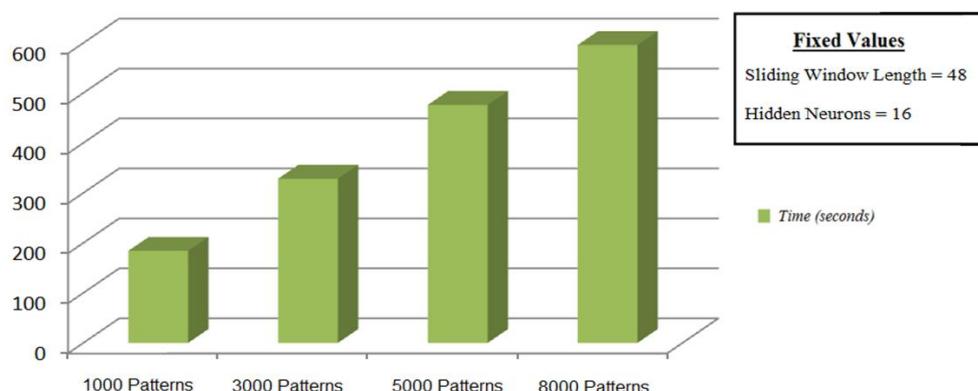
The optimization using Adding-Score approach offers, as demonstrated above, improvements which are not too significant for the non-feedback modes. In addition, for the feedback modes, the use of this optimization contributes to minimize the errors introduced into the system through the use of estimated values as input values.

The goals of the research were satisfied due to the obtained results with an error below 0.30 °C (*p*-value = 0.15) for all cases of non-feedback modes versus the state-of-the-art which reach an error around 1 °C. For feedback modes, the results were lower than 1.5 °C for the first 48 samples, corresponding to 24 h prediction time. Likewise, the inclusion of combined input-stimulus improves the prediction accuracy and it is also presented as a rectifier method against input-patterns which present irregular behaviors. Additionally, a rigorous study of the behavior of feedback architectures into the field of prediction was carried out. The study achieves favorable results for the use of time

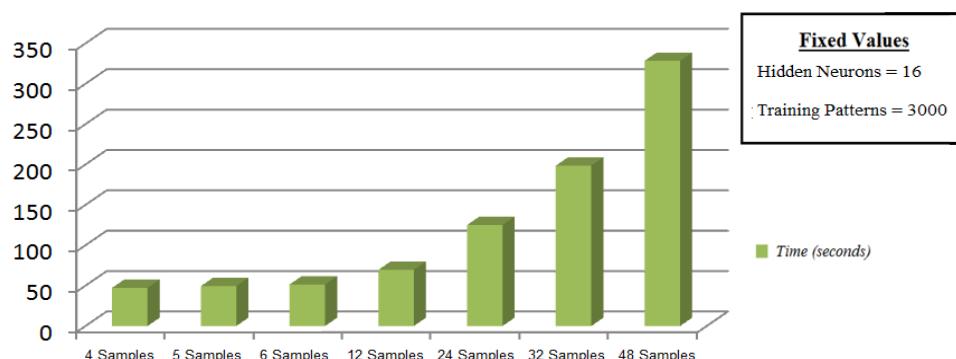
continuous estimations. Additionally, the adaptation of a score-fusion method to these architectures has even offered better performance than the one obtained by the initial system, stabilizing the response of the feedback-methods. The standardization of input-data is recommendable as a procedure to reach systems with a faster and more stable convergence.



**Figure 11.** Time course depending on the variation of the parameter of hidden neurons.



**Figure 12.** Time course depending on the variation of the parameter of training patterns.



**Figure 13.** Time course depending on the variation of the sliding window length parameter.

In Table 14 all computation times using MATLAB (Mathworks: Natick, MA, USA) in an ACER 3820TG (Intel Core i3 330M 2.13 GHz, 4 GB Ram, 500 GB HDD) can be observed:

**Table 14.** Computational times for each mode.

Type of Mode	Training Time	Testing Time Per Sample (for 1000 Samples)
MODE.1	35.33 s	$3.96 \times 10^{-2}$ s
MODE.2	52.94 s	$4.04 \times 10^{-2}$ s
MODE.3	397.92 s	33.74 s
MODE.4	363.19 s	21.76 s

It is observed as Modes without feedback are faster than Modes with feedback with the independence of the prediction for a short or large time. The difference is up to 10 times faster for training phase and 100 times for testing phase. From an absolute value point of view, the training times are shorter and the testing time can be considered as in real time. The accuracy for predicting on short time has a difference of 0.1 °C between Mode.1 and Mode.2, therefore, the feedback of Mode.2 gives a better accuracy, but a little high computational time than Mode.1 and the use of the optimal accuracy can be justified for this proposal.

As shown in Table 15, our research, using Score Fusion on ANN, improves the results obtained by previous researches using ANN except for one. In addition, compared to dataset obtained from the same meteorological stations, Score Fusion reduce error obtained by 50%, demonstrating the goodness of the method. Respect to other researches, Score Fusion on ANN reduces the error to magnitudes of tenths.

**Table 15.** Comparative with previous researches using ANN.

Reference	Error of Prediction
[6]	1 °C
[7]	2 °C
[11]	1 °C
[13] (same meteorological stations, without Score Fusion on ANN)	0.28 °C
[16]	0.01 °C
Our research (with Score Fusion on ANN)	0.13 °C

## 5. Conclusions

This paper establishes two different acting lines. The first one is based on non-feedback modes, which are able to reach significant accurate temperature predictions throughout the day. For these modes, it is recommended to use small window size (4–6 samples), a number of hidden neurons between 8 and 12 and a dataset of patterns not less than 3000–5000 observations. In addition, it was demonstrated that the use of other influential elements improves the prediction.

The second one is based on feedback modes, which are useful for temperature forecasts in short-term. These modes can be employed in social area, being interesting in urban and agriculture areas, touristic sector or even serving as useful tool for emergency services to announce weather alerts. For these latter modes, it is recommended to use medium-sized windows (24–48 samples), a number of hidden neurons between 8 and 12 and also a dataset of patterns not less than 3000–5000 observations. In addition, for a combined input-stimulus, the sampling time parameter is only recommended.

This research using ANN with Score Fusion represents an improvement versus previous research using the same meteorological stations and ANN without Score Fusion.

As a future line of this research, it could be applied in energy efficiency. Serving as a supporting instrument to manage electrical power station, to improve the energy efficiency and to prevent peaks of electrical demand, assuring the sustainability of urban development.

**Acknowledgments:** This work has been supported by Endesa Foundation and University of Las Palmas Foundation under Grant “Programa Innova Canarias 2020”.

**Author Contributions:** José Gustavo Hernández-Travieso and Carlos M. Travieso-González conceived and designed the experiments; José Gustavo Hernández-Travieso, Antonio L. Herrera-Jiménez and Antonio G. Ravelo-García performed the experiments; José Gustavo Hernández-Travieso, Antonio L. Herrera-Jiménez, Carlos M. Travieso-González, Fernando Morgado-Dias and Jesús B. Alonso Hernández analyzed the data; José Gustavo Hernández-Travieso wrote the paper.

**Conflicts of Interest:** The authors declare no conflict of interest. The founding sponsors had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, and in the decision to publish the results.

## References

1. Ramyaa, R. Frost Prediction Using Artificial Neural Networks. Master's Thesis, University of Georgia, Athens, Georgia, 2004.
2. Lezaun, M. Predicciones del Tiempo y Matemáticas. Available online: <https://dialnet.unirioja.es/servlet/articulo?codigo=2440344> (accessed on 26 November 2016).
3. Taylor, J.W.; Buizza, R. Neural network load forecasting with weather ensemble predictions. *IEEE Trans. Power Syst.* **2002**, *17*, 626–632.
4. Zhang, G.P. Time series forecasting using a hybrid ARIMA and neuronal network model. *Neurocomputing* **2003**, *50*, 159–175.
5. Sorjamaa, A.; Hao, J.; Reyhani, N.; Ji, Y.; Lendasse, A. Methodology for long-term prediction of time series. *Neurocomputing* **2007**, *70*, 2861–2869.
6. Ellouz, I.K.; Ben-Jmaa-Derbel, H.; Kanoun, O. Temperature Prediction of Soil-Pipe-Air Heat Exchanger Using Neural Networks. In Proceedings of the 6th International Multi-Conference on Systems, Signals and Devices, Djerba, Tunisia, 23–26 March 2009.
7. Fan, S.; Methaprayoon, K.; Lee, W.J. Multi-region Load Forecasting Considering Alternative Meteorological Predictions. In Proceedings of the IEEE Power and Energy Society General Meeting, Minneapolis, MN, USA, 25–29 July 2010.
8. Rastogi, A.; Srivastava, A.; Srivastava, V.K.; Pandey, A.K. Pattern Analysis Approach for Prediction Using Wavelet Neural Networks. In Proceedings of the IEEE 7th International Conference on Natural Computation (ICNC), Donghua University, Shanghai, China, 26–28 July 2011.
9. Chen, X.; Xu, A. Temperature and Humidity of Air in Mine Roadways Prediction Based on BP Neural Network. In Proceedings of the International Conference on Multimedia Technology (ICMT), Hangzhou, China, 26–28 July 2011.
10. Routh, T.K.; Bin Yousuf, A.H.; Hossain, M.N.; Asasuzzaman, M.M.; Hossain, M.I.; Husnaeen, U.; Mubarak, M. Artificial Neural Network Based Temperature Prediction and Its Impact on Solar Cell. In Proceedings of the 2012 International Conference on Informatics, Electronics & Vision (ICIEV), TBD Dhaka, Bangladesh, 18–19 May 2012.
11. Huang, H.; Chen, L.; Mohammadzaheri, M.; Hu, E.; Chen, M. Multi-Zone Temperature Prediction in a Commercial Building Using Artificial Neural Network Model. In Proceedings of the 10th IEEE International Conference on Control and Automation (ICCA), Hangzhou, China, 12–14 June 2013.
12. Taieb, S.B.; Bontempi, G.; Atiya, A.F.; Sorjamaa, A. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Syst. Appl.* **2012**, *39*, 7067–7083.
13. Vasquez, J.L.; Travieso, C.M.; Perez, T.S.; Alonso, J.B.; Briceno, J.C. Temperature Prediction Based on Different Meteorological Series. In Proceedings of the 2012 Third Global Congress on Intelligent Systems (GCIS), Wuhan, China, 6–8 November 2012.
14. Xiong, T.; Bao, Y.; Hu, Z. Beyond one-step-ahead forecasting: Evaluation of alternative multi-step-ahead forecasting models for crude oil prices. *Energy Econ.* **2013**, *40*, 405–415.
15. Hernández-Travieso, J.G.; Travieso, C.M.; Alonso, J.B. Wind Speed Modelling for the Estimation of the Wind Energy Generation. In Proceedings of the IEEE-2014 International Work Conference on Bio-inspired Intelligence (IWobi), Liberia, Costa Rica, 16–18 July 2014.
16. Bao, Y.; Xiong, T.; Hu, Z. PSO-MISMO Modeling Strategy for MultiStep-Ahead Time Series Prediction. *Trans. IEEE Cybern.* **2014**, *44*, 655–668.

17. Li, X.F.; Qin, L.L.; Ma, G.Q.; Wu, G. Modeling Greenhouse Temperature by Means of PLSR and BPNN. In Proceedings of the 35th Chinese Control Conference (CCC), Chengdu, China, 27–29 July 2016.
18. McKinney, R.; Pallipuram, V.K.; Vargas, R.; Taufer, M. From HPC Performance to Climate Modeling: Transforming Methods for HPC Predictions into Models of Extreme Climate Conditions. In Proceedings of the 2015 IEEE 11th International Conference on e-Science, Munich, Germany, 31 August–4 September 2015.
19. Prashanthi, B.; Meganathan, S.; Krishnan, R.B.; Varahasamy, R.; Swaminathan, S. Data Mining as a Tool for Hot Day Prediction during Summer Monsoon. In Proceedings of the 2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT), Nagercoil, India, 18–19 March 2016.
20. Aral, M.M.; Guan, J. Global Sea Surface Temperature and Sea Level Rise Estimation with Optimal Historical Time Lag Data. *Water* **2016**, *8*, 519.
21. Arora, K.; Dash, P. Towards dependence of tropical cyclone intensity on sea surface temperature and its response in a warming world. *Climate* **2016**, *4*, 30.
22. Prudenzi, A.; Caciotta, M.; Orsolini, C.V. The Influence of Meteorological Parameters on Italian Electric Hourly Load: The Selection of Variables of the ANN Training Set for Short Term Load Forecasting. In Proceedings of the 8th Mediterranean Electrotechnical Conference on Industrial Applications in Power Systems, Computer Science and Telecommunications, Bari, Italy, 13–16 May 1996.
23. Devi, C.J.; Reddy, P.B.S.; Kumar, K.V.; Reddy, B.M.; Nayak, R.N. ANN Approach for weather prediction using Backpropagation. *Int. J. Eng. Trends Technol.* **2012**, *3*, 19–23.
24. Serrano, A.; Soria, E.; Martín, J. *Redes Neuronales Artificiales*; Universidad de Valencia (Escuela Técnica Superior Ingeniería, Departamento de Ingeniería Electrónica): Valencia, España, 2009.
25. Gil, O.A.; Olcina, C.J. *Climatología General*; Editorial Ariel: Barcelona, Spain, 1997; pp. 110–111, 114, 116.
26. Vide, M. *Fundamentos de la Climatología Analítica*; Editorial Síntesis SA: Madrid, Spain, 1991; pp. 62, 83, 87–88.
27. Ross, A.; Nandakumar, K. Fusion, Score-Level. In *Encyclopedia of Biometrics*; Springer: New York, NY, USA, 2009; pp. 611–616.
28. Hamill, T.M. Hypothesis tests for evaluating numerical precipitation forecasts. *Weather Forecast.* **1999**, *14*, 155–167.
29. Wilcoxon, F. Individual comparisons by ranking methods. *Biom. Bull.* **1945**, *1*, 80–83.



© 2017 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).



## Discusión

Una vez presentados los trabajos publicados es posible decir que a la vista de los resultados obtenidos la hipótesis planteada inicialmente ha quedado validada y demostrada. Para recordar su contenido se reproduce seguidamente dando cumplida respuesta a su validación:

*"La obtención de predicciones meteorológicas que permitan caracterizar la variabilidad climática, reduciendo al mínimo el error existente entre la predicción y la medida real, proporciona a los procesos de generación energética un potencial que permite la mejora en la eficiencia de los procesos de generación y previsión energética mediante velocidad del viento y radiación solar."*

En los 3 artículos presentados en esta Tesis Doctoral por Compendio de Publicaciones, se han obtenido predicciones meteorológicas con errores muy bajos que permiten caracterizar la variabilidad climática de las zonas en estudio.

Dichas zonas de estudio han sido diferentes y en todas y cada una de ellas el modelo predictivo ha sido igualmente eficaz obteniendo unos errores muy bajos.

Se ha demostrado la posibilidad de incorporar los datos de predicción obtenidos a los datos técnicos de un modelo de aerogenerador para poder obtener la cantidad de energía eólica a obtener con los resultados de la predicción de velocidad del viento realizada.

En base a los experimentos realizados en los artículos, se comprueba que para caracterizar climáticamente una zona en cuanto a la predicción de un fenómeno meteorológico concreto, algunos fenómenos no tienen un aporte de información significativo.

Como muestra de la mejora que presenta el modelo predictivo desarrollado en esta Tesis Doctoral, se muestran las siguientes tablas comparativas donde se muestran los resultados obtenidos en las predicciones publicadas presentadas en este Compendio

de Publicaciones, frente al estado del arte. En fondo amarillo se muestran los artículos fruto de esta Investigación.

#### Predicción de Temperatura:

*Tabla 5: Comparativa de los resultados obtenidos en Predicción de Temperatura.*

Estudio	Error de Predicción
[Bao et al., 2014]	0.01 °C
[Chen y Xu, 2011]	0.2% - 4.9%
[Ellouz et al., 2009]	1 °C
[Huang et al., 2013]	1 °C
[Pérez et al., 2016]	0.09 °C
[Vasquez et al., 2012]	0.28 °C
Artículo 2 Tesis Doctoral	0.41 °C
Artículo 3 Tesis Doctoral	0.13 °C

#### Predicción de Velocidad del Viento:

*Tabla 6: Comparativa de los resultados obtenidos en Predicción de Velocidad del Viento.*

Estudio	Error de Predicción
[Bhaskar y Singh, 2012]	0.86 m/s
[Chen et al., 2014]	1.24 m/s
[Filik y Filik, 2017]	0.5 m/s
[Hernández et al., 2014a]	0.85 m/s
[Klodayor y Wang, 2018]	0.53 m/s
[Li J.et al., 2016]	0.55 m/s
[Luo .et al., 2018]	0.68 m/s
[Shi et al., 2013]	0.51 m/s
[Tarade y Katti, 2011]	2.24 m/s
[Ulkat y Günai, 2017]	0.32 m/s
[Xingpei et al., 2009]	1.33 m/s
[Zhao et al., 2010]	1.21 m/s
Artículo 1 Tesis Doctoral	0.29 m/s

Predicción de Radiación Solar:

Tabla 7: Comparativa de los resultados obtenidos en Predicción de Radiación Solar

Estudio	Error de Predicción
[Zhang y Qiao, 2011]	0.051 kWh/m <sup>2</sup>
[Demirtas et al., 2012]	1.69 kWh/m <sup>2</sup>
[Kaiju et al., 2013]	8 %
[Yang et al., 2013]	0.308 kWh/m <sup>2</sup>
[Hernández et al., 2014b]	0.04 kWh/m <sup>2</sup>
[Gairaa et al., 2015]	23.89%
[Hernández et al., 2015]	0.06 kWh/m <sup>2</sup>
[Koyasu et al., 2016]	5.04 kWh/m <sup>2</sup>
[Baptista et al., 2016]	0.007 %

En base a lo anteriormente expuesto, puede decirse que:

1. Se ha logrado realizar un modelo predictivo a nivel microscópico, diferente al macroscópico actual, que ha demostrado fiabilidad y robustez en las publicaciones anteriormente presentadas.  
Tal y como queda comprobado en base a los resultados presentados en los mismos.
2. Se demostrado la aplicabilidad del método independientemente del lugar geográfico en el que se desee realizar el estudio. El modelo, una vez entrenado es fácilmente y rápidamente escalable a otra ubicación geográfica independiente de la anterior. Fruto de lo cual es posible obtener diferentes predicciones en diferentes lugares.  
Al realizar dos estudios diferentes en dos localizaciones diferentes (GC y TF), además del estudio realizado en Costa Rica, se comprueba la correcta adaptación del modelo a cualquier ubicación geográfica.
3. Se han introducido novedades a la hora de realizar predicciones meteorológicas. Pudiendo obtenerse éstas sin necesidad de utilizar

imagen satélite ni radar, logrando gran precisión en las mismas. Con lo que se logra un modelo económicamente viable y de fácil instalación.

En base a los resultados obtenidos queda demostrada la robustez y fiabilidad del modelo implementado.

4. El modelo predictivo necesita pocas muestras para ser entrenado, permitiendo dedicar mayor número a la fase de test, esto redunda en una mejor adaptación del modelo logrando la convergencia en un tiempo menor.

Son necesarias un 20 % de las muestras para entrenar el sistema dejando el 80 % restante para testearlo (en el caso de GC y TF), en el caso de Costa Rica, aun habiendo menor cantidad de muestras, el entrenamiento se realiza con menos del 50 % de las mismas.

5. La información contenida en los fenómenos meteorológicos no es de la misma importancia. Ésta viene caracterizada por el fenómeno meteorológico a predecir. Según esto, un fenómeno puede eliminarse del proceso predictivo para obtener una determinada predicción e incorporarse para obtener otra de un fenómeno diferente.

Se observa como por ejemplo en función del fenómeno a predecir se eliminan de la base de datos una serie de fenómenos u otros, así como la utilización de diferentes fenómenos para obtener una predicción precisa.

6. El modelo predictivo es independiente de la frecuencia de muestreo, entendiendo como tal, que es posible aplicarlo independientemente de la estación utilizada para la captura de datos. La posible importancia de dicha frecuencia solo radica en la frecuencia con que se obtiene la predicción. Esto es, el modelo ofrece predicciones cada  $x$  tiempo, siendo esa  $x$  la frecuencia de muestreo de la estación.

7. El modelo puede considerarse de tiempo real debido al poco tiempo empleado en testear una muestra, de magnitudes de milisegundos.

El modelo es muy rápido a la hora de ofrecer un resultado de predicción una vez está correctamente calibrado y entrenado.

8. El modelo es una mejora frente a los modelos actuales de predicción meteorológica.

Tal como se observa en las comparativas de los artículos, el modelo predictivo mejora los ejemplos presentados en el estado-del-arte.

9. Aun frente a fenómenos que ofrecen una gran variabilidad a lo largo del tiempo, como pueda ser la velocidad del viento, este modelo es capaz de converger logrando predicciones precisas.

Una vez el modelo alcanza la convergencia, se comporta de manera fiable, precisa y robusta frente a las variaciones del fenómeno en estudio.



## Conclusiones

Como conclusión principal de esta Tesis Doctoral se han logrado la hipótesis y el objetivo inicialmente marcado y se ha realizado un modelo de predicción meteorológica que se diferencia de lo actual en que es un modelo a nivel microscópico y de corto plazo, unas pocas horas de antelación. Esto ha sido posible gracias a factores como los siguientes.

En primer lugar, el número de muestras utilizado en el entrenamiento del modelo predictivo. Si bien es cierto que se utilizan las muestras correspondientes a un año, esto supone un 20% del total de muestras disponibles en la base de datos. El tener tal cantidad de muestras hace posible que el modelo sea capaz de ajustarse de una manera óptima para lograr una gran precisión en los resultados obtenidos al realizar el testeo. Con una cantidad de muestras inferior, el aprendizaje del modelo no sería tan bueno con lo que la precisión finalmente obtenida no sería tan alta. Este detalle hace que el presente modelo predictivo sea mejor.

En segundo lugar, la misma arquitectura del clasificador ha sido testeada con diferentes combinaciones de fenómenos meteorológicos, con una mayor o menor cantidad de fenómenos implicados en cada experimento, lo que da muestra, en

sistema clasificador. Si a esto se le suma que, mediante la técnica de fusión sobre esta arquitectura se obtienen menores errores en las predicciones meteorológicas y una menor varianza (lo que indudablemente redunda en una mayor estabilidad), todo hace posible obtener los excelentes resultados mostrados en el apartado de Discusión (Tablas 5, 6 y 7).

Pero, sin duda, una de las mayores ventajas de este modelo predictivo radica en el poco tiempo necesario para poder entrenarlo a la hora de obtener una predicción fiable y precisa, haciendo que este modelo se posicione como una herramienta adecuada para la obtención de predicciones a corto plazo. La técnica de fusión permite que con solo 20 minutos de entrenamiento como máximo, se empiecen a obtener resultados precisos. Esto hace que sea posible ofrecer un tiempo de mejora al modelo predictivo, así como mantener un margen de maniobra a las compañías energéticas para adaptar sus sistemas de generación a la situación actual de cada momento. Con ello se logra, en el caso de la generación con combustibles fósiles, una mejora en las condiciones medioambientales al reducir las emisiones de CO<sub>2</sub>, así como un beneficio económico ya que se emplea la cantidad de combustible justa para cada instante. En el caso de la generación con energías renovables se puede ajustar el sistema a las condiciones reinantes en cada momento.

Sin duda este tiempo de entrenamiento del modelo es bajo influenciado directamente por el tamaño de la ventana deslizante, al haberse conseguido encontrar un tamaño (5 muestras) que ofrece excelentes resultados, como queda demostrado en los artículos contenidos en esta Tesis Doctoral por Compendio de Publicaciones. Con un tamaño de solo 5 muestras, implica que la ANN posea solo 5 neuronas de entrada. Junto con las 24 de la capa oculta y la única neurona de la capa de salida, forman una configuración que aporta una gran rapidez al modelo a la hora de realizar el entrenamiento y posteriormente, en el testeo, ofrecer un tiempo de test por muestra del orden de milésimas de segundo. Haciendo que el modelo se comporte casi como un sistema en tiempo real.

Este objetivo cumplido permite que este modelo sea aplicable para lograr una mejora en la eficiencia energética en los procesos de generación, tanto con energías

renovables, como mediante combustibles fósiles. Todo ello, logrando caracterizar la variabilidad climática de la zona en estudio.

Del mismo modo, se ha logrado validar la hipótesis inicialmente trazada al comienzo de esta investigación, tal como ha quedado demostrado en los trabajos publicados a lo largo de esta Investigación.

Además de la conclusión principal se han obtenido una serie de conclusiones secundarias de manera holística.

Se ha podido obtener un modelo de predicción meteorológica basado exclusivamente en los datos suministrados por estaciones meteorológicas, sin ser necesaria la utilización de imagen por satélite, ni utilizar radares meteorológicos para obtener predicciones precisas y fiables.

Se ha logrado un modelo de predicción meteorológica que es independiente de la localización geográfica con la que sea entrenado. Esto posibilita enormemente su instalación en un lugar remoto de aquél en el que ha sido originalmente entrenado y permite obtener resultados precisos en un intervalo de tiempo reducido.

Se ha implementado un modelo predictivo que necesita un número de muestras para ser entrenado mucho menor que el utilizado para su testeo. Esto posibilita la puesta en marcha del modelo de una manera veloz una vez se ha logrado entrenar al mismo.

Se ha comprobado la cantidad cualitativa de información que poseen los diferentes fenómenos meteorológicos a la hora de ser utilizados para obtener una predicción. En función del fenómeno meteorológico a predecir, será necesaria una combinación de diversos fenómenos meteorológicos para poder obtener una predicción precisa del mismo. Según esto, un fenómeno puede eliminarse del proceso predictivo para obtener una determinada predicción e incorporarse para obtener otra de un fenómeno diferente.

Se ha conseguido realizar un modelo capaz de obtener predicciones precisas trabajando casi en tiempo real. Debido al poco tiempo necesario a la hora de procesar una muestra en su testeo, de magnitudes de milisegundos.

Por su parte, el tiempo de entrenamiento necesario para obtener predicciones precisas varía en función del sistema de clasificación empleado y de la configuración interna que se le da al mismo, hasta obtener de manera heurística su correcta configuración.

Se ha logrado un modelo predictivo que es independiente de la frecuencia con la que la estación recoge las muestras de información meteorológica, siendo éste tan solo un factor a tener en cuenta para saber para qué horizonte temporal se obtendrá la predicción. Esto significa que si la estación recopila datos cada hora, el resultado de la predicción será para la hora siguiente. Si por el contrario la información se recoge cada 30 minutos, la predicción se obtendrá para 30 minutos.

Se ha comprobado que para horizontes temporales más lejanos en el tiempo, el modelo predictivo deja de ser tan preciso como sí lo es para las predicciones a corto plazo.

Se ha conseguido un modelo predictivo que puede acoplarse a un aerogenerador y ofrecer datos de energía generada por el mismo en función de la recta de carga que posea.

La generación de estos modelos predictivos abre una gran cantidad de nuevas aplicaciones de las predicciones obtenidas pudiendo emplearse en todos y cada uno de los sectores que se vean afectados por las condiciones meteorológicas a la hora de realizar sus actividades o de ofrecer información y/o ayuda en función de estos mismos parámetros.

Se ha conseguido un modelo predictivo que supone una mejora frente a los modelos actuales de predicción meteorológica.

Aun frente a fenómenos que ofrecen una gran variabilidad a lo largo del tiempo, como pueda ser la velocidad del viento, este modelo es capaz de converger logrando

predicciones precisas. Una vez el modelo alcanza la convergencia, se comporta de manera fiable, precisa y robusta frente a las variaciones del fenómeno en estudio.

En lo relativo a las líneas futuras de esta Investigación dentro de las líneas de investigación del Programa de Doctorado en Empresa, Internet y Tecnologías de las Comunicaciones (EmITIC) algunas de ellas podrían ser:

- Obtención de los valores interpolados de predicciones en aquellas zonas donde no se disponga de estaciones meteorológicas, para poder obtener energía renovable.
- Realización y caracterización del modelo en tiempo real. Culminación de la etapa actual marcada en un 80% de desarrollo actualmente.
- Realización de la caracterización y mapeado climatológico de la isla de Gran Canaria para conseguir la mejora en la eficiencia energética.
- Mejora de la interpolación para lograr incluir en el modelo los datos de los momentos en que la estación meteorológica está en labores de mantenimiento o sufre avería.
- Ampliar la ventana temporal de predicciones en las que el modelo ofrece resultados precisos. Intentar llegar a días o semanas de antelación con mayor precisión y fiabilidad que los modelos meteorológicos actuales.
- Obtener predicciones meteorológicas en las que la frecuencia de muestreo de la estación sea diferente de la frecuencia con que se obtienen las predicciones.

Estas líneas futuras se ajustan a la segunda línea de investigación del Programa de Doctorado en Empresa, Internet y Tecnologías de las Comunicaciones (EmITIC), titulada “Sociedad, empresa y Tecnologías de la Información y el Conocimiento” en los temas siguientes:

- Computación adaptativa y neurociencia computacional.

Debido a los sistemas de clasificación empleados se desarrolla una tarea de neurociencia computacional y computación adaptativa.

- Organización, comportamiento humano y sostenibilidad.

Al colaborar a la mejora de la eficiencia energética colabora con la sostenibilidad del medio ambiente, encontrándose encuadrada en este tema.

- Inteligencia artificial.

Debido a los sistemas de clasificación empleados.

- Procesado de señal.

## Bibliografía

- [Allen et al., 2017] Allen, D.J., Tomlin, A.S., Bale, C.S.E., Skea, A., Vosper, S., Gallani, M.L. "A boundary layer scaling technique for estimating near-surface wind energy using numerical weather prediction and wind map data." *Applied Energy* 2017, 208, pp. 1246-1257
- [Andrade y Bessa, 2017] Andrade, J.R., Bessa, R.J. "Improving Renewable Energy Forecasting With a Grid of Numerical Weather Predictions." *IEEE Transactions on Sustainable Energy* 2017, 8, no. 4, pp. 1571-1580
- [Aral y Guan, 2016] Aral, M.M.; Guan, J. "Global Sea Surface Temperature and Sea Level Rise Estimation with Optimal Historical Time Lag Data." *Water* 2016, 8, 519.
- [Arora y Dash, 2016] Arora, K.; Dash, P. "Towards dependence of tropical cyclone intensity on sea surface temperature and its response in a warming world." *Climate* 2016, 4, 30.
- [Artis, 2012] Jean Paul Artis (2012) EE.UU. Patente Nº. US 8,095,315 B2. Washington, DC: U.S. Patent and Trademark Office.
- [Bao et al., 2014] Bao, Y.; Xiong, T.; Hu, Z. "PSO-MISMO Modeling Strategy for MultiStep-Ahead Time Series Prediction." *Trans. IEEE Cybern.* 2014, 44, 655–668.
- [Baptista et al., 2016] Baptista, D., Abreu, S., Travieso-González, C., Morgado-Dias, F. "Hardware implementation of an artificial neural network model to predict the energy production of a photovoltaic system." *Microprocessors and Microsystems*, 49, pp. 77-86
- [Bhaskar y Singh, 2012] Bhaskar, K.; Singh, S.N., "AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network," *IEEE Transactions on Sustainable Energy*, vol.3, no.2, pp. 306, 315, April 2012.
- [Chen et al., 2014] Niya Chen; Zheng Qian; Nabney, I.T.; Xiaofeng Meng, "Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction," *IEEE Transactions on Power Systems*, vol.29, no.2, pp. 656, 665, March 2014.

[Chen y Xu, 2011] Xuexi Chen; Ameng Xu, "Temperature and humidity of air in mine roadways prediction based on BP neural network," 2011 International Conference on Multimedia Technology (ICMT), pp. 1273, 1276, 26-28 July 2011.

[Cramer et al., 2017] Cramer, S., Kampouridis, M., Freitas, A.A., Alexandridis, A.A. "An extensive evaluation of seven machine learning methods for rainfall prediction in weather derivatives." Expert Systems with Applications 2017, 85, pp. 169-181.

[Demirtas et al., 2012] Demirtas, M.; Yesilbudak, M.; Sagiroglu, S.; Colak, I., "Prediction of solar radiation using meteorological data," 2012 International Conference on Renewable Energy Research and Applications (ICRERA), pp. 1, 4, 11-14 November 2012.

[Donida et al., 2018] Donida Labati, R.; Genovese, A.; Piuri, V.; Scotti, F.; Sforza, G. "A Decision Support System for Wind Power Production." IEEE Transactions on System, Man, and Cybernetics: Systems 2018, no. 99, pp. 1-15.

[Du et al., 2018] Y. F. Du, L. Jiang, C. Duan, Y. Z. Li and J. S. Smith, "Energy Consumption Scheduling of HVAC Considering Weather Forecast Error Through the Distributionally Robust Approach," in IEEE Transactions on Industrial Informatics, vol. 14, no. 3, pp. 846-857, March 2018.

[Ellouz et al., 2009] Ellouz, I.K.; Ben Jmaa Derbel, H.; Kanoun, O., "Temperature prediction of Soil-Pipe-Air Heat Exchanger using neural networks," 6th International Multi-Conference on Systems, Signals and Devices, 2009 (SSD '09), pp. 1, 6, 23-26 March 2009.

[Eroshenko y Khalyasmaa, 2018] S. A. Eroshenko and A. I. Khalyasmaa, "Assessment of the learning sample size and pattern impact on the SPS generation short-term forecasting," 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus), Moscow, 2018, pp. 617-621.

[Filik y Filik, 2017] Ümmühan Başaran Filik, Tansu Filik, "Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir," Energy Procedia, Volume 107, 2017, pp. 264-269.

[Gairaa et al., 2015] K. Gairaa, F. Chellali, S. Benkaciali, Y. Messlem and K. Abdallah, "Daily global solar radiation forecasting over a desert area using NAR neural networks comparison with conventional methods," 2015 International Conference on Renewable Energy Research and Applications (ICRERA), Palermo, 2015, pp. 567-571.

[Gofrani et al., 2017] M. Ghofrani, N. Niromand, R. Azimi and M. Ghayekhloo, "A novel data mining method for high accuracy solar radiation forecasting," 2017 North American Power Symposium (NAPS), Morgantown, WV, 2017, pp. 1-6.

[Haykin, 1999] Haykin, S. "Neural networks. A comprehensive foundation," 2<sup>nd</sup> edition. Prentice Hall International, Inc., Upper Saddle River, USA.

[Hernández et al., 2014a] Hernández-Travieso, J. G.; Travieso, C.M. and Alonso, J. B., "Wind speed modelling for the estimation of the wind energy generation," 3rd IEEE International Work-Conference on Bioinspired Intelligence, Liberia, 2014, pp. 44-49.

[Hernández et al., 2014b] Hernández-Travieso, J. G.; Travieso, C.M.; Alonso, J. B. and Dutta, M.K., "Solar radiation modelling for the estimation of the solar energy generation," 2014 Seventh International Conference on Contemporary Computing (IC3), Noida, 2014, pp. 536-541.

[Hernández et al., 2015] Hernández-Travieso, J.G.; Travieso, C.M.; Alonso, J.B. and Dutta, M.K., "Applying data normalization for the Solar Radiation Modelling," Proceedings of the 11th International Conference on Energy, Environment, Ecosystems and Sustainable Development (EEESD'15), Tenerife, Spain, 10-12 January, 2015, pp. 134-139.

[Houthuys et al., 2017] Houthuys, L., Karevan, Z., Suykens, J.A.K. "Multi-view LS-SVM regression for black-box temperature prediction in weather forecasting." In Proceedings of the 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 14-17 May 2017

[Huang et al., 2013] Hao Huang; Lei Chen; Mohammadzaheri, M.; Hu, E.; Minlei Chen, "Multi-zone temperature prediction in a commercial building using artificial neural network model," 2013 10th IEEE International Conference on Control and Automation (ICCA), pp. 1896, 1901, 12-14 June 2013.

[IIC, 2016a] Instituto de Ingeniería del Conocimiento, Información del seminario "Predicción inmediata y a muy corto plazo de la radiación solar a partir de datos de satélite y modelos numéricos" realizada por la AEMET y Red Eléctrica de España, 2016, <http://www.iic.uam.es/energias/prediccion-radiacion-solar-corto-plazo/> Fecha de consulta: 13 de agosto de 2018.

[IIC, 2016b] Instituto de Ingeniería del Conocimiento, Presentación en formato PDF realizada en el seminario "Predicción inmediata y a muy corto plazo de la radiación solar a partir de datos de satélite y modelos numéricos" realizada por la AEMET y Red Eléctrica de España, 2016, <http://www.iic.uam.es/pdf/seminarioNOV2016.pdf>

Fecha de consulta: 13 de agosto de 2018.

[ITC, 2018] Instituto Tecnológico de Canarias, Proyecto G.R.A.C.I.O.S.A. (Generación Renovable con Almacenamiento y Consumos Inteligentes para la Operación de Redes de distribución con Sistemas de Autoconsumo) desarrollado en la isla de La Graciosa (Islas Canarias), 2018, [http://www.itccanarias.org/web/itc/proyectos-eerr/proyecto\\_graciosa.jsp?lang=es](http://www.itccanarias.org/web/itc/proyectos-eerr/proyecto_graciosa.jsp?lang=es) Fecha de consulta: 13 de agosto de 2018.

[Jian et al., 2018] Z. Jian, L. Kai, L. Zhanzhan and L. Ruimin, "Study of monthly electricity sales forecasting based on seasonal adjustment and multi-factor correction method," 2018 Chinese Control And Decision Conference (CCDC), Shenyang, China, 2018, pp. 2086-2090.

[Kaiju et al., 2018] L. Kaiju, L. Xuefeng, M. Chaoxu and W. Dan, "Short-term photovoltaic power prediction based on T-S fuzzy neural network," 2018 33rd Youth Academic Annual Conference of Chinese Association of Automation (YAC), Nanjing, China, 2018, pp. 620-624.

[Khodayar y Wang, 2018] M. Khodayar and J. Wang, "Spatio-temporal Graph Deep Neural Network for Short-term Wind Speed Forecasting," in IEEE Transactions on Sustainable Energy (Early Access).

[Khodayar et al., 2018] M. Khodayar, J. Wang and M. Manthouri, "Interval Deep Generative Neural Network for Wind Speed Forecasting," in IEEE Transactions on Smart Grid (Early Access).

[Koyasu et al., 2016] T. Koyasu, K. Yukita, K. Ichiyangai, M. Minowa, M. Yoda and K. Hirose, "Forecasting variation of solar radiation and movement of cloud by sky image data," 2016 IEEE International Conference on Renewable Energy Research and Applications (ICRERA), Birmingham, 2016, pp. 401-406.

[Li J. et al., 2016] J. Li, R. Wang and T. Zhang, "Wind speed prediction using a cooperative coevolution genetic algorithm based on back propagation neural network," 2016 IEEE Congress on Evolutionary Computation (CEC), Vancouver, BC, 2016, pp. 4578-4583.

[Li X.F. et al., 2016] Li, X.F.; Qin, L.L.; Ma, G.Q.; Wu, G. "Modeling Greenhouse Temperature by Means of PLSR and BPNN." In Proceedings of the 35th Chinese Control Conference (CCC), Chengdu, China, 27–29 July 2016.

[Lin y Weng, 2018] L. Lin and F. Weng, "Estimation of Hurricane Maximum Wind Speed Using Temperature Anomaly Derived From Advanced Technology Microwave Sounder," in IEEE Geoscience and Remote Sensing Letters, vol. 15, no. 5, pp. 639-643, May 2018.

[Lin et al., 2018] Q. Lin, Q. Wang, G. Zhang, Y. Shi, H. Liu and L. Deng, "Maximum daily load forecasting based on support vector regression considering accumulated temperature effect," 2018 Chinese Control And Decision Conference (CCDC), Shenyang, 2018, pp. 5199-5203.

[Luo et al., 2018] X. Luo et al., "Short-term Wind Speed Forecasting via Stacked Extreme Learning Machine With Generalized Correntropy," in IEEE Transactions on Industrial Informatics (Early Access).

[McKinney et al., 2015] McKinney, R.; Pallipuram, V.K.; Vargas, R.; Taufer, M. "From HPC Performance to Climate Modeling: Transforming Methods for HPC Predictions into Models of Extreme Climate Conditions." In Proceedings of the 2015 IEEE 11th International Conference on e-Science, Munich, Germany, 31 August–4 September 2015.

[Mecikalski et al., 2014] John Mecikalski, Wayne M. MacKenzie, Jr., John Robert Walker (2014) EE.UU. Patente Nº. US 8,818,029 B1. Washington, DC: U.S. Patent and Trademark Office.

[Mengquiao et al, 2017] Mengjiao, Q., Zhihang, L., Zhenhong, D. "Red tide time series forecasting by combining ARIMA and deep belief network." Knowledge-Based System 2017, 125, pp. 39-52.

[Mert et al., 2016] Mert, İ., Karakuş, C. & Üneş, F. "Estimating the energy production of the wind turbine using artificial neural network." Neural Comput & Applic (2016) 27: 1231.

[Murata et al., 2018] Murata, A., Ohtake, H., Oozeki, T. "Modeling of uncertainty of solar irradiance forecasts on numerical weather predictions with the estimation of multiple confidence intervals." Renewable Energy 2018, 117, pp. 193-201.

[Naing y Srinivasan, 2010] Lin Phy Naing; Srinivasan, D., "Estimation of solar power generating capacity," IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), 2010, pp.95,100, 14-17 June 2010.

[Pérez et al., 2016] Pérez-Vega, A.; Travieso, C. M.; Hernández-Travieso, J. G.; Alonso, J. B.; Dutta, M. K. and Singh, A., "Forecast of temperature using support vector machines," 2016 International Conference on Computing, Communication and Automation (ICCCA), Noida, 2016, pp. 388-392.

[Prashanthi et al., 2016] Prashanthi, B.; Meganathan, S.; Krishnan, R.B.; Varahasamy, R.; Swaminathan, S. "Data Mining as a Tool for Hot Day Prediction during Summer Monsoon." In Proceedings of the 2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT), Nagercoil, India, 18–19 March 2016.

[Rastogi et al., 2011] Rastogi, A.; Srivastava, A.; Srivastava, V.K.; Pandey, A.K., "Pattern analysis approach for prediction using Wavelet Neural Networks," 2011 Seventh International Conference on Natural Computation (ICNC), pp. 695, 699, 26-28 July 2011.

[Ravela et al., 2014] Srinivas Ravela, William J. Dupree, Timothy R. Langlois, Marilyn M. Wolfson, Christopher M. Yang (2014) EE.UU. Patente Nº. US 8,625,840 B2. Washington, DC: U.S. Patent and Trademark Office.

[Refaat et al., 2018] S. S. Refaat, O. H. Abu-Rub and H. Nounou, "ANN based prognostication of the PV panel output power under various environmental conditions," 2018 IEEE Texas Power and Energy Conference (TPEC), College Station, TX, 2018, pp. 1-6.

[Routh et al., 2012] Routh, T.K.; Bin Yousuf, A.H.; Hossain, M.N.; Asasuzzaman, M.M.; Hossain, M.I.; Husnaeen, U.; Mubarak, M., "Artificial neural network based temperature prediction and its impact on solar cell," 2012 International Conference on Informatics, Electronics & Vision (ICIEV), pp. 897, 902, 18-19 May 2012.

[Ruffin y Venayagamoorthy, 2009] Ruffing, S.M.; Venayagamoorthy, G.K., "Short to Medium Range Time Series Prediction of Solar Irradiance Using an Echo State Network," 15th International Conference on Intelligent System Applications to Power Systems, 2009. ISAP '09, pp. 1, 6, 8-12 November 2009.

[Salcedo-Sanz et al., 2014] S. Salcedo-Sanz, C. Casanova-Mateo, J. Muñoz-Marí and G. Camps-Valls, "Prediction of Daily Global Solar Irradiation Using Temporal Gaussian Processes," in IEEE Geoscience and Remote Sensing Letters, vol. 11, no. 11, pp. 1936-1940, November 2014.

[Sagar et al., 2017] Sagar, S.K., Rajeevan, M., Bhaskara Rao, S.V., Mitra, A.K. "Prediction skill of rainstorm events over India in the TIGGE weather prediction models." Atmospheric Research 2017, 198, 194-204

[Shi et al., 2013] Shi Nan; Zhou Su-quan; Zhu Xian-hui; Su Xun-wen; Zhao Xiao-yan, "Wind speed forecasting based on grey predictor and genetic neural network models," 2013 International Conference on Measurement, Information and Control (ICMIC), vol.02, pp.1479,1482, 16-18 August 2013.

[Shi et al., 2018] X. Shi, W. Lu, Y. Zhao and P. Qin, "Prediction of Indoor Temperature and Relative Humidity Based on Cloud Database by Using an Improved BP Neural Network in Chongqing," in IEEE Access, vol. 6, pp. 30559-30566, 2018.

[Shu et al., 2010] Shu Fan; Methaprayoon, K.; Wei-Jen Lee, "Multi-region load forecasting considering alternative meteorological predictions," 2010 IEEE Power and Energy Society General Meeting, pp. 1, 7, 25-29 July 2010.

[Snegirev et al., 2017] D. A. Snegirev, S. A. Eroshenko, R. T. Valiev and A. I. Khalyasmaa, "Algorithmic realization of short-term solar power plant output forecasting," 2017 IEEE II International Conference on Control in Technical Systems (CTS), St. Petersburg, 2017, pp. 228-231.

[Soussié et al., 2007] Olivier Soussié, Francois Coulmeau (2007) EE.UU. Patente Nº. US 2007/0179703 A1. Washington, DC: U.S. Patent and Trademark Office.

[Szeles et al., 2017] Szeles, J., Kubota, N., Woo, J. "Weather forecast support system implemented into robot partner for supporting elderly people using fuzzy logic." In Proceedings of the 2017 Joint 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS), Otsu, Japan, 27-30 June 2017

[Tarade y Katti, 2011] Tarade, R. S.; Katti, P.K., "A comparative analysis for wind speed prediction," 2011 International Conference on Energy, Automation, and Signal (ICEAS), pp. 1, 6, 28-30 December 2011.

[Tillotson et al., 2010] Brian J. Tillotson, David A. Whelan (2010) EE.UU. Patente Nº. US 7,728,759 B2. Washington, DC: U.S. Patent and Trademark Office.

[Ulkat y Günai, 2017] Ulkat D. & Günay, M.E. "Prediction of mean monthly wind speed and optimization of wind power by artificial neural networks using geographical

and atmospheric variables: case of Aegean Region of Turkey." Neural Comput & Applic (2017).

[ULL, 2018] Universidad de La Laguna, "La ULL consigue mejorar la predicción de energía fotovoltaica en redes inteligentes", 2018,  
<https://www.ull.es/portal/noticias/2018/mejora-prediccion-energia-fotovoltaica/> Fecha de consulta: 13 de agosto de 2018.

[Valverde et al., 2014] M.C. Valverde, Ernesto Araujo, H. Campos Velho, "Neural network and fuzzy logic statistical downscaling of atmospheric circulation-type specific weather pattern for rainfall forecasting," In Applied Soft Computing, Volume 22, 2014, pp. 681-694.

[Vasquez et al., 2012] Vasquez, J.L.; Travieso, C.M.; Perez, T.S.; Alonso, J.B.; Briceno, J.C., "Temperature Prediction Based on Different Meteorological Series," 2012 Third Global Congress on Intelligent Systems (GCIS), pp. 104, 107, 6-8 November 2012.

[Wada, 2006] Masakazu Wada (2006) EE.UU. Patente Nº. US 7,076,368 B2. Washington, DC: U.S. Patent and Trademark Office.

[Wang et al., 2011] Jianping Wang; Yunlin Xie; Chenghui Zhu; Xiaobing Xu, "Daily solar radiation prediction based on Genetic Algorithm Optimization of wavelet neural network," 2011 International Conference on Electrical and Control Engineering (ICECE), pp.602,605, 16-18 Sept. 2011.

[Wu Y.K. et al., 2018] Y. K. Wu, P. E. Su, T. Y. Wu, J. S. Hong and Y. H. Mohammad, "Probabilistic Wind Power Forecasting Using Weather Ensemble Models," in IEEE Transactions on Industry Applications (Early Access).

[Wu F. et al., 2018] F. Wu, N. Zhou, P. Ju and X. P. Zhang, "Wind-Wave Coupling Model for Wave Energy Forecast," in IEEE Transactions on Sustainable Energy, Issue 99 (Early Access).

[Wu y Keong, 2011] Wu Ji, Keong Chan Chee, "Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN," Solar Energy, Volume 85, Issue 5, 2011, pp. 808-817.

[Xiao y Ai, 2018] F. Xiao and Q. Ai, "Data-Driven Multi-Hidden Markov Model-Based Power Quality Disturbance Prediction that Incorporates Weather Conditions," in IEEE Transactions on Power Systems (Early Access).

[Xingpei et al., 2009] Li Xingpei; Liu Yibing; Xin Weidong, "Wind speed prediction based on genetic neural network," 4th IEEE Conference on Industrial Electronics and Applications, 2009. ICIEA 2009, pp. 2448, 2451, 25-27 May 2009.

[Yang et al., 2013] Xiyun Yang; Feifei Jiang; Huan Liu, "Short-term solar radiation prediction based on SVM with similar data," 2nd IET Renewable Power Generation Conference (RPG 2013), 2013, pp.1,4, 9-11 Sept. 2013.

[Yoshida et al., 2016] S. Yoshida, H. Suzuki, T. Kitajima, A. M. Kassim and T. Yasuno, "Correction method of wind speed prediction system using predicted wind speed fluctuation," 2016 55th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE), Tsukuba, 2016, pp. 1054-1059.

[Young et al., 2012] Philip John Young, Angelo Genghi (2012) EE.UU. Patente Nº. US 8,100,0049 B2. Washington, DC: U.S. Patent and Trademark Office

[Zhang B. et al., 2018] B. Zhang, L. Tang and M. Roemer, "Probabilistic Planning and Risk Evaluation Based on Ensemble Weather Forecasting," in IEEE Transactions on Automation Science and Engineering, vol. 15, no. 2, pp. 556-566, April 2018.

[Zhang T. et al., 2018] T. Zhang, M. P. Wan, B. F. Ng and S. Yang, "Model Predictive Control for Building Energy Reduction and Temperature Regulation," 2018 IEEE Green Technologies Conference (GreenTech), Austin, TX, 2018, pp. 100-106.

[Zhao et al., 2010] Pan Zhao; Junrong Xia; Yiping Dai; Jiaxing He, "Wind speed prediction using support vector regression," the 5th IEEE Conference on Industrial Electronics and Applications (ICIEA), 2010, pp.882,886, 15-17 June 2010.

[Zheng y Qiao, 2011] Jianwu Zeng; Wei Qiao, "Short-term solar power prediction using

## Anexo I

En el presente Anexo I se presentan los resultados gráficos de que la obtención de un modelo de predicción meteorológica para una zona geográfica concreta, bajo unas condiciones específicas, no es impedimento para que éste pueda ser fácilmente exportado a una localización geográfica distinta a la anterior.

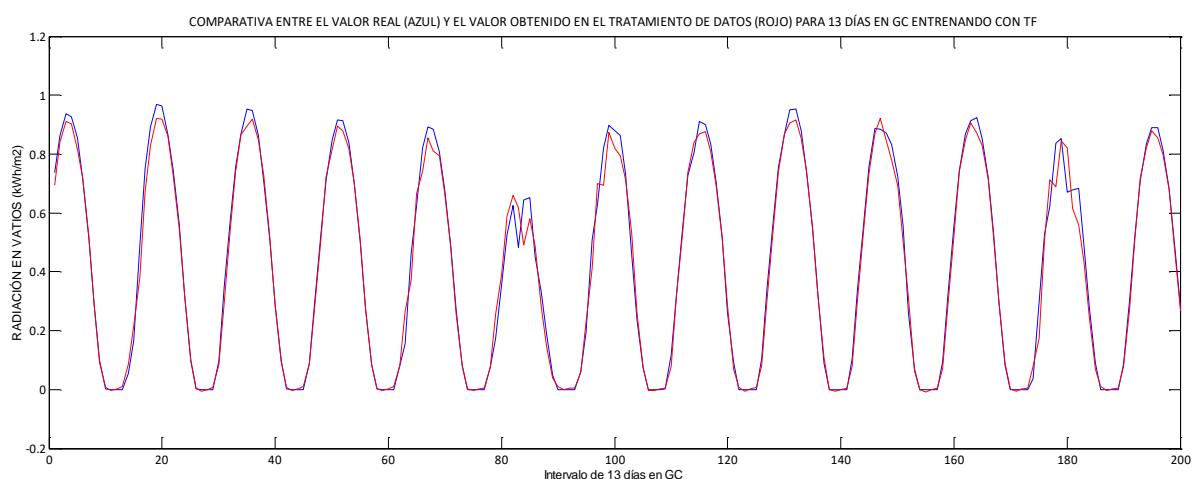
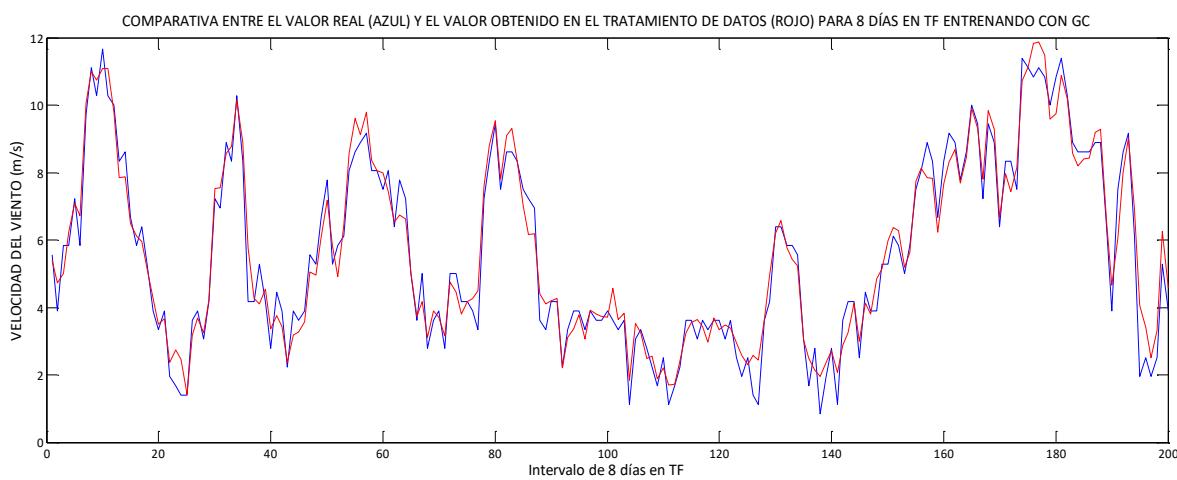


Ilustración 8: Radiación solar en el Aeropuerto de Gran Canaria, utilizando el modelo predictivo entrenado para el Aeropuerto Tenerife Sur.



*Ilustración 9: Velocidad del viento en el Aeropuerto de Tenerife Sur, utilizando el modelo predictivo entrenado para el Aeropuerto Gran Canaria.*

A la vista de los resultados obtenidos queda comprobado y validado que es posible entrenar el modelo predictivo con los datos de una ubicación geográfica y testearlo en otra, en este caso las distancias entre ambas localizaciones es de más de 100 kilómetros.

## Anexo II

En el presente Anexo II se presentan las publicaciones en Congresos Internacionales, participaciones en Ferias y Encuentros Tecnológicos, Proyecto Final de Carrera, Trabajo Fin de Grado y Trabajo Fin de Máster dirigidos, así como los galardones y noticias de prensa derivadas de esta investigación a lo largo de su historia.

A lo largo de la investigación realizada hasta llegar a este punto, se han realizado publicaciones en diversos Congresos Internacionales:

- CANAGUA 2017: 11<sup>a</sup> Feria Internacional Canagua&Energía. Soluciones Integrales de Agua y Energía para Entornos Aislados (CANAGUA&ENERGÍA 2017) del 05 al 08 de octubre de 2017, Las Palmas de Gran Canaria (Gran Canaria, España).
- ICCCA 2016: International Conference on Communication and Automation (ICCA 2016) del 29 al 30 de junio de 2016, Greater Noida (India).

- EEESD 2015: 11th International Conference On Energy, Environment, Ecosystems and Sustainable Development (EEESD '15) del 10 al 12 de enero de 2015, Arona (Tenerife, España).
- IC3 2014: Seventh International Conference on Contemporary Computing (IC3) del 07 al 09 de agosto de 2014, Noida (India)
- IWOBI 2014: International Work Conference On Bio-inspired Intelligence (IWOBI 2014) del 16 al 18 de julio de 2014, Liberia (Costa Rica).

Participación en Ferias:

- Gran Canaria Ecológica. Feria de Ecología y Sostenibilidad, Granja Agrícola Experimental del Cabildo de Gran Canaria, Arucas (Gran Canaria, España), 12-13 de mayo de 2018.
- TRANSIERE 2016: 5º Foro Europeo para la Ciencia, Tecnología e Innovación, Palacio de Ferias y Congresos de Málaga, 10-11 de febrero de 2016, Málaga (España) (gracias a la Oficina de Transferencia de Resultados de Investigación, OTRI, de la Universidad de Las Palmas de Gran Canaria).
- GENERA 2014: 17ª Feria Internacional de Energía y Medio Ambiente, Institución Ferial de Madrid (IFEMA), 6-8 de mayo de 2014, Madrid (España) (gracias a la Oficina de Transferencia de Resultados de Investigación, OTRI, de la Universidad de Las Palmas de Gran Canaria).

Encuentro Tecnológico:

- #MeLoApunto, organizado por la Sociedad de Promoción Económica de Gran Canaria, Fundación Canaria Parque Científico Tecnológico de la Universidad de Las Palmas de Gran Canaria y Palet Express Cajasiete, Parque Científico Tecnológico de la Universidad de Las Palmas de Gran Canaria 22 de marzo de 2018.

Los galardones obtenidos por la presente investigación han sido los siguientes:

- Premio Accésit de la I Cátedra Telefónica de la Universidad de Las Palmas de Gran Canaria en su categoría Proyecto de Innovación / Investigación en el año 2017. Con el Trabajo titulado: Modelo de estimación meteorológica para la generación de energías renovables.
- Premio OPTIMA Finnancial Planners a la Mejor Trayectoria Académica en Ingeniería de Telecomunicación. XXXV Convocatoria Premios Ingenieros de Telecomunicación Colegio Oficial de Ingenieros de Telecomunicación (COIT) y Asociación española de Ingenieros de Telecomunicación (AEIT), en el año 2015.
- Beca de la Fundación Universitaria de Las Palmas dentro del Proyecto Innova Canarias 2020 en su XXX Edición, bajo mecenazgo de la Fundación Endesa, para el desarrollo del proyecto titulado Metodología para el Desarrollo de un Modelo de Predicción Climática a Corto Plazo para la Optimización de las Centrales Eléctricas basado en las Series Temporales de las Variables Climáticas. Año 2013.

Del mismo modo, a lo largo del tiempo en el que se ha desarrollado esta investigación, el doctorando ha dirigido los siguientes Proyecto Final de Carrera, Trabajo Fin de Grado y Trabajo Fin de Máster:

- Alumno: D. Robison Adalio Ferrera Moreira.

Título del Proyecto: Extracción de Información de las Webs de Estaciones Meteorológicas para su Predicción en Tiempo Real.

Tutores: Dr. Carlos M. Travieso González,  
José Gustavo Hernández Travieso.

Titulación: Grado en Ingeniería en Tecnologías de la Telecomunicación,  
Mención en Sistemas de Telecomunicación.

Universidad: Universidad de Las Palmas de Gran Canaria.

Fecha de lectura: Septiembre de 2016.

- Alumno: D. Abrahán Pérez Vega.

Título del Proyecto: Sistemas de Predicción Aplicados sobre las Variables Meteorológicas.

Tutores: Dr. Carlos M. Travieso González,  
José Gustavo Hernández Travieso.

Titulación: Máster Universitario en Ingeniería de Telecomunicación.

Universidad: Universidad de Las Palmas de Gran Canaria.

Fecha de lectura: Febrero de 2015.

- Alumno: D. Antonio Luis Herrera Jiménez.

Título del Proyecto: Sistema de Predicción Meteorológico basado en Redes Neuronales Artificiales.

Tutores: Dr. Carlos M. Travieso González,  
José Gustavo Hernández Travieso.

Titulación: Ingeniero de Telecomunicación.

Universidad: Universidad de Las Palmas de Gran Canaria.

Fecha de lectura: Septiembre de 2014.

También se ha dado difusión en prensa del proyecto a raíz del Premio obtenido en la XXXV Convocatoria Premios Ingenieros de Telecomunicación Colegio Oficial de Ingenieros de Telecomunicación (COIT) y Asociación española de Ingenieros de Telecomunicación (AEIT):

- Entrevista a José Gustavo Hernández Travieso, premio de 'Ingenieros de Telecomunicación 2014'. Programa Hoy por Hoy El Drago, Cadena SER, 19 de noviembre de 2015.  
<http://play.cadenaser.com/audio/081RD010000000311161//>
- Nota de prensa Universidad de Las Palmas de Gran Canaria, 09 de octubre de 2015.  
<https://www.ulpgc.es/noticia/estudiante-ulpgc-galardonado-premio-mejor-trayectoria-academica-xxxv-premios-ingeneros>
- Nota de prensa Universia News España, 09 de octubre de 2015.  
<https://es.universianews.net/2015/10/09/un-estudiante-de-master-de-la-ulpgc-galardonado-con-el-premio-a-la-mejor-trayectoria-academica-en-los-xxxv-premios-ingeneros-de-telecomunicacion/>
- Nota de prensa Revista Zona Teleco Canarias nº20, octubre de 2015.  
[https://issuu.com/acitcanarias/docs/revista\\_n\\_20-octubre](https://issuu.com/acitcanarias/docs/revista_n_20-octubre)





UNIVERSIDAD DE LAS PALMAS  
DE GRAN CANARIA

Vicerrectorado de Investigación,  
Innovación y Transferencia

Cátedra Telefónica ULPGC

**I CONCURSO CÁTEDRA TELEFÓNICA DE LA  
UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA**

**D I P L O M A**

Por el presente se otorga el merecido reconocimiento a

**JOSÉ GUSTAVO HERNÁNDEZ TRAVIESO**

tras deliberación por parte del jurado designado como:

**PREMIO ACCÉSIT  
PROYECTO DE INNOVACIÓN / INVESTIGACIÓN**

En Las Palmas de Gran Canaria, a 17 de octubre de 2017.

A handwritten signature in black ink, appearing to read "José Pablo Suárez Rivero".

D. José Pablo Suárez Rivero  
Vicerrector de Investigación,  
Innovación y Transferencia







MODELOS DE PREDICCIÓN METEOROLÓGICA BASADOS EN MÉTODOS DE CLASIFICACIÓN ORIENTADOS A LA  
MEJORA DE LA EFICIENCIA ENERGÉTICA EN LOS PROCESOS DE GENERACIÓN.  
TESIS DOCTORAL JOSÉ GUSTAVO HERNÁNDEZ TRAVIESO

88

**PREMIO OPTIMA FINANCIAL PLANNERS A LA MEJOR TRAYECTORIA ACADÉMICA**

Dentro de la XXXV edición Premios Ingenieros de Telecomunicación 2014, se me ha concedido el Premio Óptima Financial Planners a la Mejor Trayectoria Académica en Ingeniería de Telecomunicación. En el mismo se ha tenido en cuenta el expediente académico (80%) y la actividad académica extraordinaria (20%) como, por ejemplo, estancias en el extranjero, premios becas, publicaciones y formación extra-curricular.

Dentro de estas actividades académicas extraordinarias, destacar la Beca INNOVA Canarias 2020, obtenida en su XXX edición. Estas becas las concede la Fundación Universitaria de Las Palmas, y cuentan con el inestimable apoyo de empresas privadas que deciden ayudar con su mecenazgo a unos proyectos de investigación determinados. En este caso concreto se contó con el mecenazgo de la Fundación Endesa, el cual permitió realizar el proyecto titulado "Metodología para el desarrollo de un modelo de predicción climática de corto plazo para la optimización de las centrales eléctricas basado en las series temporales de las variables climáticas" bajo la dirección del Dr. D. Carlos M. Travieso González. El Trabajo Fin de Máster titulado "Predictor M Meteorológico basado en Series Temporales de Estaciones Meteorológicas", y que obtuvo la clasificación de Sobresaliente con 10 mención de Matrícula de Honor, fue una continuación de esta línea de investigación abierta con la Beca INNOVA, y que tendrá continuidad en la Tesis Doctoral a realizar (bajo la dirección del Dr. D. Carlos M. Travieso González) en los estudios de Doctorado dentro del Programa de Empresa, Internet y Tecnologías de las Comunicaciones (EMTIC) de la Universidad de La Laguna.



Actualmente trabajo para MM CICOM Telecomunicaciones, S.L. en el Departamento de Ingeniería del HFDSL System, proyecto en el que participa la Universidad de Las Palmas de Gran Canaria a través del Instituto para el Desarrollo Tecnológico y la Innovación

En Comunicaciones (DeTIC), la Universidad Politécnica de Madrid y MM CICOM Telecomunicaciones, S.L., El HFDV System se encuentra dentro del programa COINCIDENTE (Cooperación en Investigación Científica y Desarrollo en Tecnologías Estratégicas) del Ministerio de Defensa del Gobierno de España, el cual tiene como principal objetivo aprovechar las tecnologías desarrolladas en el ámbito civil para incorporar soluciones tecnológicas innovadoras de interés para el Ministerio de Defensa.

El HFDSL System es un módem de comunicaciones digital orientado a las comunicaciones HF (3 a 30 MHz) que permite la transmisión de voz (digital interactiva o analógica) o datos a alta velocidad en modo continuo no-estándar (ARQ) o según el estándar NATO STANAG 5066. El responsable por parte de la Universidad de Las Palmas de Gran Canaria es el Dr. D. Iván A. Pérez Álvarez, por parte de la Universidad Politécnica de Madrid el Dr. D. Sanmartín, Pedro Ballón y MM CICCOM Telecomunicaciones, S.L.

2015  
ZTC

20  
21

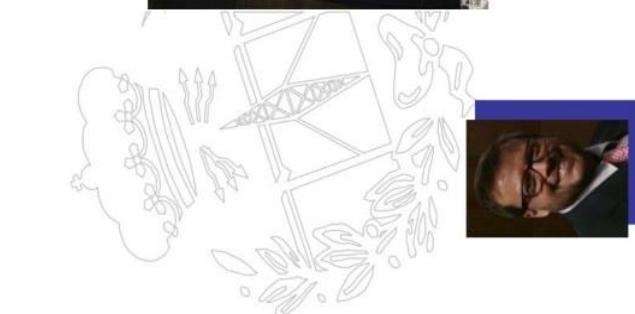
E.I.T.E., Escuela de Ingeniería de  
Telecomunicación y Electrónica  
Campus de Tafira – ULPGC  
ES5017 Las Palmas de Gran Canaria

E-mail: acit@colt.es

C/ El Pilar, 40 1ºA  
38002 Santa Cruz de Tenerife

80

Premio OPTIMA Financial Planners a la Travectoria Académica



D. José G. Hernández Travieso

143



## Un estudiante de Máster de la ULPGC, galardonado con el Premio a la Mejor Trayectoria Académica en los XXXV Premios 'Ingenieros de Telecomunicación'

09 de octubre de 2015



El estudiante del Máster Universitario en Ingeniería de Telecomunicación y actual Doctorando del Programa de Empresa, Internet y Tecnologías de las Comunicaciones de la Universidad de Las Palmas de Gran Canaria (ULPGC), José Gustavo Hernández Travieso, ha sido galardonado con el **Premio OPTIMA Financial Planners a la Mejor Trayectoria Académica** en la **XXXV edición de los Premios 'Ingenieros de Telecomunicación 2014'**, que otorgan anualmente la **Asociación Española de Ingenieros de Telecomunicación** y el **Colegio Oficial de Ingenieros de Telecomunicación**.

José Gustavo Hernández recogerá el premio en la Gala Oficial que se celebrará el **viernes 16 de octubre**, a partir de las **12 horas**, en el **Instituto de Ingeniería de España en Madrid** (c/ General Arrando, 38).

El **Jurado de los Premios** ha galardonado al estudiante de la ULPGC basándose en los méritos académicos obtenidos a lo largo de sus estudios de Máster, así como por las actividades extra académicas y curriculares, como el trabajo realizado en la División de Ingeniería de Comunicaciones y la División de Señales y Comunicaciones, ambas pertenecientes al **Instituto para el Desarrollo Tecnológico y la Innovación en Comunicaciones (IDeTIC) de la ULPGC**.

Además, José Gustavo Hernández obtuvo la **Beca INNOVA Canarias 2020**, concedida por la Fundación Universitaria de Las Palmas en su XXX edición, a través de la cual realizó el **proyecto "Metodología para el desarrollo de un modelo de predicción climática de corto plazo para la optimización de las centrales eléctricas basado en las series temporales de las variables climáticas"** bajo la dirección del Dr. Carlos M. Travieso González.

Esta línea de investigación también se plasmó en su **Trabajo Fin de Máster "Predictor Meteorológico basado en Series Temporales de Estaciones Meteorológicas"**, con el que obtuvo la clasificación de Sobresaliente 10 con mención de Matrícula de Honor.

Todo el trabajo realizado a lo largo del Máster cristalizó en la obtención del **Premio Extraordinario de Fin de Título de los estudios del Máster Universitario en Ingeniería de Telecomunicación por la Universidad de Las Palmas de Gran Canaria (Promoción 2013-2014)**.

Actualmente, José Gustavo Hernández cursa estudios de **Doctorado del Programa Empresa, Internet y Tecnologías de las Comunicaciones (EmITIC)** de la ULPGC, con una investigación que sigue la línea de

MODELOS DE PREDICCIÓN METEOROLÓGICA BASADOS EN MÉTODOS DE CLASIFICACIÓN ORIENTADOS A LA MEJORA DE LA EFICIENCIA ENERGÉTICA EN LOS PROCESOS DE GENERACIÓN.  
TESIS DOCTORAL JOSÉ GUSTAVO HERNÁNDEZ TRAVIESO

investigación iniciada con la Beca INNOVA Canarias 2020 y continuada con el Trabajo de Final del Máster orientada a la predicción meteorológica enfocada a la mejora de la eficiencia energética, siendo el Director de su Tesis Doctoral el **Dr. Carlos M. Travieso González**.

Asimismo, colabora en el **Proyecto HFDVL System** en el que participa la ULPGC a través del **Instituto para el Desarrollo Tecnológico y la Innovación en Comunicaciones (IDeTIC)** y bajo la dirección del **Dr. Iván Pérez Álvarez**, junto con la **Universidad Politécnica de Madrid** y la empresa **MM CICOM Telecomunicaciones, S.L.**

El **HFDVL System** es un módem de comunicaciones digital orientado a las comunicaciones HF (3 a 30 MHz) que permite la transmisión de voz (digital interactiva o analógica) o datos a alta velocidad en modo continuo no-ARQ o según el estándar NATO STANAG 5066.

---

© Universidad de Las Palmas de Gran Canaria. ULPGC



**Programa Innova Canarias 2020®  
30ª Edición**

La Fundación Canaria Universitaria de Las Palmas  
en sesión de Consejo Ejecutivo de 12 de diciembre de 2013  
acordó conceder a

**D. JOSÉ GUSTAVO HERNÁNDEZ TRAVIESO**

Una beca para investigación patrocinada por  
**FUNDACIÓN ENDESA**

Por importe de  
**6000**

Para el Proyecto Titulado

Metodología para el desarrollo de un modelo de predicción climática  
de corto plazo para la optimización de las centrales eléctricas basado  
en las series temporales de las variables climáticas

En Las Palmas de Gran Canaria, 18 de diciembre de 2013





