

MÁSTER EN INGENIERÍA DE TELECOMUNICACIÓN



Trabajo Fin de Máster

Predicción de extremos de viento en parques eólicos mediante técnicas de machine learning.



ESCUELA POLITECNICA

Autora: Sara Ortega Lázaro

Tutora: Dra. Silvia Jiménez Fernández

UNIVERSIDAD DE ALCALÁ
Escuela Politécnica Superior

MÁSTER EN INGENIERÍA DE TELECOMUNICACIÓN

Trabajo Fin de Máster

Predicción de extremos de viento en parques eólicos
mediante técnicas de machine learning.

Autora: Sara Ortega Lázaro

Tutora: Dra. Silvia Jiménez Fernández

TRIBUNAL:

Presidente: Dr. Miguel Ángel Sotelo Vázquez.

Vocal 1º: Dr. Sancho Salcedo Sanz.

Vocal 2º: Dra. Silvia Jiménez Fernández.

FECHA: 13/09/2016

“Life is too short to wake up with regrets. So love the people who treat you right. Forget about those who don’t. Believe everything happens for a reason. If you get a chance, take it. If it changes your life, let it. Nobody said life would be easy, the just promised it would most likely be worth it.”

- Harvey MacKay.

AGRADECIMIENTOS

Quiero dedicar unas líneas a todas aquellas personas que, de una forma u otra, me han apoyado durante estos años de formación, en especial en estos últimos años como estudiante de Máster, y a lo largo de la realización de este proyecto.

En primer lugar quiero agradecer a mis padres y a mi hermano todo su cariño y paciencia, especialmente en situaciones de estrés y nervios de las que sólo ellos podían sacarme. Gracias a mis padres por escucharme, aun cuando no entendían nada de lo que les estaba hablando, y a mi hermano, que se ha convertido en todo un ejemplo de superación y fuerza de voluntad.

Gracias a Diego, mi apoyo incondicional, el que me hace ver las cosas de forma más positiva y siempre ha estado dispuesto a ayudarme dejándome acaparar su ordenador unas semanas.

Quiero agradecer también a Laura Cornejo toda su ayuda desde el primer momento, respondiéndome a cualquier duda que me surgiera y que hizo esa primera etapa del trabajo más llevadera.

Gracias a mis compañeros de clase, de todos vosotros me llevo unos recuerdos muy buenos y sé que aunque ya estemos tomando caminos diferentes siempre tendremos tiempo para juntarnos y ponernos al día.

No me olvido tampoco de mis amigos de Guadalajara, con los que siempre había tiempo para charlar y desconectar.

Y finalmente, gracias a los profesores de la Universidad de Alcalá en general y a Silvia en particular, no sólo por todo lo que nos han enseñado a lo largo de estos años, sino también por haber hecho que seamos las personas que somos hoy en día, capaces de salir fuera y enfrentarnos a las nuevas situaciones que nos depara nuestra vida laboral.

Mil gracias a todos por haberme acompañado en esta etapa y por haberme aportado tanto.

ÍNDICE DEL TRABAJO

ÍNDICE DEL TRABAJO	1
ÍNDICE DE FIGURAS.....	3
ÍNDICE DE TABLAS.....	5
RESUMEN	7
ABSTRACT	9
RESUMEN EXTENDIDO	11
1. INTRODUCCIÓN, PLANTEAMIENTO Y OBJETIVOS.....	13
1.1. INTRODUCCIÓN.....	13
1.2. PLANTEAMIENTO	14
1.2.1. <i>Energía eólica</i>	14
Definición.....	14
Cómo se obtiene.....	15
Curva Potencia-Velocidad.....	15
Ventajas y desventajas de la energía eólica	17
1.2.2. <i>Repercusión de la energía eólica en la red eléctrica</i>	18
1.2.3. <i>Energía eólica en España</i>	20
Parques eólicos marinos en España.....	21
Energía eólica de media potencia y energía minieólica.....	22
Líneas futuras de la energía eólica en España	22
1.3. OBJETIVOS.....	23
1.3.1. <i>Motivación</i>	23
1.3.2. <i>Predicción</i>	25
1.3.3. <i>Aplicación de técnicas machine learning</i>	27
2. MÉTODOS.....	30
2.1. INTRODUCCIÓN AL SOFT COMPUTING.....	30
2.2. REDES NEURONALES	31
2.2.1. <i>Redes SFLN</i>	33
2.2.2. <i>Extreme Learning Machine</i>	35
Implementación del algoritmo ELM en Matlab	37
2.3. COMPUTACIÓN EVOLUTIVA.....	40
2.3.1. <i>Algoritmos Genéticos</i>	41
2.3.2. <i>Problema de Selección de Características</i>	43
Implementación del Algoritmo Genético en Matlab	45
3. MATERIAL.....	49
3.1. DATOS DE VELOCIDAD DE VIENTO	49
3.2. DATOS DE REANÁLISIS.....	50
4. RESULTADOS	52
4.1. INTRODUCCIÓN.....	52
4.2. PREPARACIÓN INICIAL DE LOS DATOS.....	54
4.3. EXPERIMENTO BASE.....	58
4.4. EXPERIMENTO CON REANÁLISIS	69

4.5. EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS	82
5. CONCLUSIONES	94
6. PLIEGO DE CONDICIONES	105
6.1. CONDICIONES MATERIALES Y DE EQUIPOS	105
6.2. CONDICIONES DE EJECUCIÓN.....	106
7. PRESUPUESTO	107
BIBLIOGRAFÍA	113

ÍNDICE DE FIGURAS

FIGURA 1. PARQUE EÓLICO EN GALICIA, ESPAÑA	13
FIGURA 2. ESQUEMA DEL SISTEMA ELÉCTRICO PENINSULAR. [6].....	14
FIGURA 3. PARTES DE UN AEROGENERADOR. [7]	15
FIGURA 4. CURVA DE POTENCIA DE UN AEROGENERADOR. [8].....	16
FIGURA 5. ESPECIFICACIONES AEROGENERADOR GAMESA 2.5 MW. [8].....	17
FIGURA 6. COBERTURA EÓLICA DE LA DEMANDA Y PRECIO HORARIO DEL PVPC. (A) 06/05/16 Y (B) 07/05/16 [4].....	19
FIGURA 7. COBERTURA DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN 2015. [13].....	20
FIGURA 8. DISPOSICIÓN DEL CECRE Y LOS CENTROS DE CONTROL, ASÍ COMO PARQUES DE GENERACIÓN Y SUBESTACIONES. [22]..	24
FIGURA 9. COMUNICACIÓN ENTRE EL CECRE Y LOS DISTINTOS CENTROS DE CONTROL. [22]	25
FIGURA 10. TÉCNICAS SOFT-COMPUTING EMPLEADAS EN ESTE TRABAJO.	30
FIGURA 11. ESTRUCTURA DE UNA RED NEURONAL. [35].....	31
FIGURA 12. ESTRUCTURA DE UNA NEURONA ARTIFICIAL EN IA.....	32
FIGURA 13. ESTRUCTURA DE UNA RED SLFN.	34
FIGURA 14. EJEMPLO DE VALIDACIÓN CRUZADA DE 4-ITERACIONES.	39
FIGURA 15. EJEMPLO DE VALIDACIÓN CRUZADA ALEATORIA.	39
FIGURA 16. PROCEDIMIENTO DE LAS TÉCNICAS DE COMPUTACIÓN EVOLUTIVA.....	41
FIGURA 17. PSEUDOCÓDIGO PARA ALGORITMO GENÉTICO SIMPLE. [46]	42
FIGURA 18. DIAGRAMA DEL MÉTODO “WRAPPER” PARA SELECCIÓN DE CARACTERÍSTICAS. [36].....	44
FIGURA 19. DIAGRAMA DE DISEÑO DE LA FUNCIÓN DE FITNESS.....	45
FIGURA 20. DIAGRAMA DE BLOQUES DEL ALGORITMO GENÉTICO IMPLEMENTADO.....	47
FIGURA 21. DATOS DE VELOCIDAD DE VIENTO HORARIOS DE LA MATRIZ DE PARTIDA.	50
FIGURA 22. DIAGRAMA EXPERIMENTO BASE.....	52
FIGURA 23. DIAGRAMA EXPERIMENTO CON REANÁLISIS.....	53
FIGURA 24. DIAGRAMA EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS.	53
FIGURA 25. FRAGMENTO DE DATASET EN EL EXPERIMENTO BASE.	54
FIGURA 26. FRAGMENTO DE DATASET EN EL EXPERIMENTO CON REANÁLISIS.....	56
FIGURA 27. EJEMPLO DE LIMPIEZA DE DATOS NO VÁLIDOS DEL DATASET.	57
FIGURA 28. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA FIJA EXP. BASE.	59
FIGURA 29. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA MÓVIL EXP. BASE.....	61
FIGURA 30. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA FIJA.....	64
FIGURA 31. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA MÓVIL.	67
FIGURA 32. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO BASE PARA VENTANA FIJA VS VENTANA MÓVIL.	68
FIGURA 33. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA FIJA EXP. CON REANÁLISIS.	71

FIGURA 34. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA MÓVIL EXP. CON REANÁLISIS. 72

FIGURA 35. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA FIJA. 76

FIGURA 36. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA MÓVIL. 79

FIGURA 37. COMPARATIVA EXPERIMENTO BASE Y EXPERIMENTO CON REANÁLISIS PARA VENTANA FIJA. 80

FIGURA 38. COMPARATIVA EXPERIMENTO BASE Y EXPERIMENTO CON REANÁLISIS PARA VENTANA MÓVIL. 81

FIGURA 39. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO CON REANÁLISIS PARA VENTANA FIJA VS VENTANA MÓVIL. 82

FIGURA 40. COMPARATIVA EXPERIMENTO CON REANÁLISIS Y EXPERIMENTO CON SELECCIÓN PARA VENTANA FIJA. 87

FIGURA 41. COMPARATIVA EXPERIMENTO CON REANÁLISIS Y EXPERIMENTO CON SELECCIÓN PARA VENTANA MÓVIL. 91

FIGURA 42. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO CON SELECCIÓN PARA VENTANA FIJA VS VENTANA MÓVIL. 92

FIGURA 43. EVOLUCIÓN DEL ERROR MÍNIMO EN EL ALGORITMO GENÉTICO PARA (A) VENTANA FIJA Y (B) VENTANA MÓVIL. 99

FIGURA 44. CLASIFICACIÓN DE EJEMPLOS VÁLIDOS PARA EL DISEÑO DE LA RED. 100

FIGURA 45. CLASIFICACIÓN DE EJEMPLOS NO VÁLIDOS PARA EL DISEÑO DE LA RED. 101

FIGURA 46. ANÁLISIS DE TARGET Y VELOCIDAD MEDIA PARA EL CONJUNTO DE EJEMPLOS. 102

FIGURA 47. ANÁLISIS DE ERRORES PARA LA SALIDA DE PREDICCIÓN SIN REANÁLISIS. 102

FIGURA 48. ANÁLISIS DE ERRORES PARA LA SALIDA DE PREDICCIÓN CON REANÁLISIS. 103

FIGURA 49. COMPARATIVA DE PREDICCIÓN ANTES Y DESPUÉS DE INCLUIR REANÁLISIS. 103

ÍNDICE DE TABLAS

TABLA 1. ARGUMENTOS DE ENTRADA Y SALIDA DE LA FUNCIÓN ELM.....	38
TABLA 2. ARGUMENTOS DE ENTRADA Y SALIDA DE LA FUNCIÓN DE FITNESS Y DE LOS OPERADORES DE CRUCE, MUTACIÓN Y SELECCIÓN.....	48
TABLA 3. MATRIZ DE DATOS DE VELOCIDAD DE VIENTO EN PEÑAPARDA.....	49
TABLA 4. CARACTERÍSTICAS DE REANÁLISIS OBTENIDAS DEL ERA-INTERIM.....	51
TABLA 5. MATRIZ DE DATOS DE REANÁLISIS EN PEÑAPARDA.....	51
TABLA 6. ASIGNACIÓN DE PREDICTORES DE REANÁLISIS CON VENTANA MÓVIL.....	55
TABLA 7. ANÁLISIS DE DATOS NO VÁLIDOS EN LA MATRIZ DE ATRIBUTOS PARA VENTANA FIJA.....	56
TABLA 8. ANÁLISIS DE DATOS NO VÁLIDOS EN LA MATRIZ DE ATRIBUTOS PARA VENTANA MÓVIL.....	58
TABLA 9. MATRICES VÁLIDAS PARA EL EXPERIMENTO BASE.....	58
TABLA 10. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[10,150] CON VF EXP. BASE.....	60
TABLA 11. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[10,150] CON VF EXP. BASE.....	60
TABLA 12. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[10,150] CON VM EXP. BASE.....	61
TABLA 13. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[10,150] CON VM EXP. BASE.....	61
TABLA 14. RESULTADOS DE PREDICCIÓN CON VENTANA FIJA PARA EL EXP. BASE.....	63
TABLA 15. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA FIJA.....	64
TABLA 16. RESULTADOS DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. BASE.....	66
TABLA 17. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA MÓVIL.....	67
TABLA 18. MATRICES VÁLIDAS PARA EL EXPERIMENTO CON REANÁLISIS.....	69
TABLA 19. CARACTERÍSTICAS DE ENTRADA PARA EL EXPERIMENTO CON REANÁLISIS.....	70
TABLA 20. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[20,150] CON VF EXP. CON REANÁLISIS.....	71
TABLA 21. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[20,150] CON VF EXP. CON REANÁLISIS.....	71
TABLA 22. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[20,150] CON VM EXP. CON REANÁLISIS.....	73
TABLA 23. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[20,150] CON VM EXP. CON REANÁLISIS.....	73
TABLA 24. RESULTADOS DE PREDICCIÓN CON VENTANA FIJA PARA EL EXP. CON REANÁLISIS.....	75
TABLA 25. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA FIJA.....	76
TABLA 26. RESULTADOS DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. CON REANÁLISIS.....	78
TABLA 27. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA MÓVIL.....	79
TABLA 28. MATRICES VÁLIDAS PARA EL EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS.....	83
TABLA 29. CARACTERÍSTICAS SELECCIONADAS POR EL ALGORITMO GENÉTICO PARA VENTANA FIJA Y ERROR MÍNIMO ASOCIADO AL INDIVIDUO.....	84
TABLA 30. RESULTADO DE PREDICCIÓN CON VENTANA FIJA PARA EL EXP. CON SELECCIÓN.....	86
TABLA 31. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON SELECCIÓN CON VENTANA FIJA.....	87

TABLA 32. CARACTERÍSTICAS SELECCIONADAS POR EL ALGORITMO GENÉTICO PARA VENTANA MÓVIL Y ERROR MÍNIMO ASOCIADO AL INDIVIDUO..... 88

TABLA 33. RESULTADO DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. CON SELECCIÓN. 90

TABLA 34. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON SELECCIÓN CON VENTANA MÓVIL..... 91

TABLA 35. CARACTERÍSTICAS DE LOS MEJORES INDIVIDUOS ENCONTRADOS POR EL ALGORITMO GENÉTICO PARA VENTANA FIJA Y VENTANA MÓVIL. 93

TABLA 36. RESUMEN DE RESULTADOS PARA VENTANA FIJA. 95

TABLA 37. RESUMEN DE RESULTADOS PARA VENTANA MÓVIL..... 95

TABLA 38. CONJUNTO DE CARACTERÍSTICAS DE REANÁLISIS DEL MEJOR INDIVIDUO PARA VENTANA FIJA. 96

TABLA 39. CONJUNTO DE CARACTERÍSTICAS COMUNES A LOS MEJORES INDIVIDUOS PARA VENTANA FIJA..... 96

TABLA 40. EJEMPLO CON TARGET SUPERIOR A LA VELOCIDAD MEDIA. 101

TABLA 41. COSTE DE LOS RECURSOS HARDWARE EMPLEADOS EN EL PROYECTO. 107

TABLA 42. COSTE DE LOS RECURSOS SOFTWARE EMPLEADOS EN EL PROYECTO. 107

TABLA 43. COSTE DE LOS RECURSOS MATERIALES EMPLEADOS EN EL PROYECTO. 108

TABLA 44. COSTE DE LA MANO DE OBRA EMPLEADA EN EL PROYECTO. 108

TABLA 45. PRESUPUESTO TOTAL DE EJECUCIÓN MATERIAL. 109

TABLA 46. PRESUPUESTO DE EJECUCIÓN POR CONTRATA..... 109

TABLA 47. TOTAL HONORARIOS FACULTATIVOS. 110

TABLA 48. PRESUPUESTO FINAL. 111

RESUMEN

El potencial de la energía eólica es tan grande que se busca optimizar su integración en la red eléctrica para sacar ventaja de esta energía. Esto implica solucionar problemas relacionados con la velocidad del viento, debido a su variabilidad y aleatoriedad, que dificultan su gestión y la posibilidad de predecir su velocidad.

Este trabajo presenta una metodología de predicción de extremos de viento a corto plazo basada en un Algoritmo Genético y una ELM (Extreme Learning Machine), empleando distintos conjuntos de variables de predicción para mejorar su rendimiento, y llevando a cabo una selección de características (FSP) con el Algoritmo Genético que permite mejorar la precisión de la predicción.

Palabras clave: Predicción de extremos de viento, Algoritmo genético, Extreme Learning Machine, Error de predicción, Selección de características.

ABSTRACT

The potential of wind power is so big that its integration into power system must be optimized in order to take advantage of this energy. This implies the solution of different problems related to wind speed, due to its variability and randomness, which make difficult its management and wind speed prediction.

This work presents a methodology for short-term extreme wind speed prediction based on a Genetic Algorithm and an Extreme Learning Machine (ELM), using different sets of predictive variables to improve its performance, and carrying out the Feature Selection Problem (FSP) with the Genetic Algorithm that allows improving the prediction accuracy.

Keywords: Extreme wind speed prediction, Genetic Algorithm, Extreme Learning Machine, Prediction error, Feature selection.

RESUMEN EXTENDIDO

Actualmente existen muchos estudios centrados en el aprovechamiento del enorme potencial que ofrece la energía eólica. Esta fuente de energía renovable tiene múltiples ventajas, entre las que se encuentran ser una energía limpia e inagotable. Además, esta fuente de energía supone una alternativa, frente a los combustibles fósiles, de obtener energía eléctrica abaratando costes y frenando el impacto ambiental que supone la explotación masiva de recursos naturales.

Por este motivo, se estudia la manera de integrar este tipo de energía en la red eléctrica convencional de la forma más eficiente posible. En este contexto aparece uno de los principales problemas que presenta la energía eólica, y es debido a que el viento tiene una naturaleza aleatoria e impredecible que obliga a establecer medidas de seguridad en los parques eólicos, para detener la generación cuando se detecta un cambio brusco de viento o un aumento elevado de su velocidad. Otro inconveniente que presenta este tipo de energía es que no se puede producir de forma constante, ya que depende del carácter del viento, y hasta ahora no se ha encontrado una forma eficiente de almacenarla, por tanto habrá momentos donde la generación eléctrica proveniente de la energía eólica no sea suficiente para cubrir la demanda eléctrica.

Este tipo de hechos hacen indispensable seguir disponiendo de otra fuente de energía que sí sea gestionable y que tenga una respuesta inmediata para satisfacer la demanda de electricidad de la población. En este caso se trata de la Red Eléctrica, que actualmente convive con la energía eléctrica generada por los aerogeneradores.

Entre los puntos fuertes de investigación en el sector se encuentra la mejora de la sensibilidad de los aerogeneradores para facilitar la integración en el sistema eléctrico, aunque estos problemas tienen como origen la imposibilidad de conocer el comportamiento que tendrá la producción eléctrica en los parques, ya que siempre va a existir cierto error de predicción que sería ideal poder reducirlo al mínimo posible.

Ser capaces de predecir velocidades de viento futuras y minimizar el error cometido en la predicción trae consigo múltiples ventajas, no sólo para la planificación responsable de la energía eléctrica que será necesario generar con las centrales eléctricas para garantizar el suministro, sino también para que las empresas propietarias de los parques eólicos puedan conocer la capacidad de generación de sus parques y tomar mejores decisiones en el mercado.

El objetivo de este Trabajo Fin de Máster es emplear técnicas *machine learning* para llevar a cabo la predicción de extremos de viento a corto plazo. Este tipo de técnicas proceden de la rama de la inteligencia artificial y tienen como objetivo enseñar a las máquinas a resolver cierto problema para el que son entrenadas mediante un conjunto de ejemplos que les dotan de experiencia, sin necesidad de que exista algún tipo de programación o guía previa que les diga cómo deben interpretar estos ejemplos. De esta forma, estas técnicas se pueden aplicar a problemas donde el ser humano no es capaz de hallar la relación que existe entre los datos conocidos del pasado y determinar el valor que tendrán en el presente o futuro.

Para la realización de este trabajo se ha seguido un proceso que se estructura en los siguientes capítulos.

En el primer capítulo de esta memoria se realiza una introducción a este trabajo, describiendo lo esencial sobre la energía eólica y su repercusión en la red eléctrica, y encuadrando el presente trabajo en la necesidad real que existe de mejorar la predicción eólica. Además, se realiza una introducción a las técnicas *machine learning* y los distintos estudios que demuestran su éxito para enfrentarse a este tipo de problemas.

En el segundo capítulo se introduce el término de Soft-Computing y se profundiza en las técnicas basadas en redes neuronales artificiales y en las técnicas de computación evolutiva. Sobre estas técnicas se expone su base teórica y el tipo de algoritmo que se empleará en este trabajo: Extreme Learning Machine, como algoritmo rápido de entrenamiento de redes neuronales, y el Algoritmo Genético, para resolver el problema de selección de características (FSP). Se expondrá también la manera en que estos algoritmos han sido implementados en la herramienta de software Matlab.

El tercer capítulo muestra los datos de los que se dispone para realizar la predicción de extremos de viento. Se analizan, por un lado, los datos de velocidad de viento recogidos en el parque eólico de Peñaparda, y por otro lado, los datos de reanálisis extraídos del ERA-Interim, procedentes de cuatro estaciones cercanas al parque eólico.

Es en el cuarto capítulo donde se plantean los distintos experimentos que se van a realizar, así como la preparación inicial que requieren los datos proporcionados para formar el conjunto de ejemplos que va a servir de entrenamiento a la red neuronal. Posteriormente se llevan a cabo los experimentos planteados, comenzando por un experimento base que emplea únicamente datos de velocidad de viento para predecir, continuando con un experimento donde se incorporan a las variables de predicción los datos de reanálisis, y finalmente realizando una selección de características de entrada para reducir el conjunto de variables de predicción que se tengan a la entrada de la red neuronal. Para cada experimento se contrastará su objetivo con los resultados obtenidos y se analizará detalladamente, a medida que se avanza, si los cambios realizados de un experimento a otro suponen una mejora en la salida de predicción.

Por último, en el quinto capítulo, se describen brevemente los pasos que se han seguido para este estudio y los resultados que se han originado con cada uno de ellos, comparando el rendimiento de cada modelo y exponiendo los detalles más relevantes de cada fase del trabajo. En este apartado se pretende exponer las conclusiones obtenidas con este estudio, además de describir los inconvenientes que se han encontrado a lo largo de éste y las decisiones que se han tomado para salvarlos. Parte importante de este apartado es también el análisis realizado sobre los datos empleados en este estudio para justificar, en cierta medida, el error de predicción encontrado.

Finalmente se presentan las posibles líneas futuras del trabajo, un pliego de condiciones y un presupuesto detallado del coste que conlleva ese Trabajo Fin de Máster.

1. INTRODUCCIÓN, PLANTEAMIENTO Y OBJETIVOS

1.1. INTRODUCCIÓN

Desde hace algunos años la preocupación de la humanidad por la preservación del medioambiente es cada vez más notoria. Que la sociedad evoluciona a marchas forzadas es un hecho innegable, y el tremendo impacto ambiental que supone el uso de recursos naturales no puede ser pasado por alto.

Cada vez son menos los recursos no renovables que pueden ser explotados para su aprovechamiento, ya sea porque la tasa de consumo es superior a la tasa de recuperación de estos, impidiendo su regeneración, o por los cambios originados en los terrenos por la actividad humana [1].

Todos somos conscientes de los problemas ambientales que se están generando, y está en nuestras manos buscar soluciones para evitar esta continua degradación.

Aquí es donde entran en juego las energías renovables, o energías limpias, obtenidas de forma natural, regenerándose en periodos de tiempo relativamente cortos por medios naturales (o permitiendo un abastecimiento elevado), y que no generan residuo alguno que contribuya a la contaminación del medio [2]. Este tipo de energías suponen una alternativa frente al uso de recursos no renovables, y los estudios sobre su aprovechamiento y mejoras en eficiencia, aunque son cada vez mayores, tienen aún camino por recorrer.

Es el caso de la energía eólica, producida por los aerogeneradores que componen un parque eólico. Esta energía es generada por el viento, siendo totalmente limpia, renovable y accesible. Además, un solo aerogenerador podría abastecer a unos 2.000 hogares por año, por lo cual supone una gran opción para reducir la dependencia que existe actualmente en el uso del petróleo [3]. A este planteamiento se une además que España se encuentra en una situación privilegiada para el aprovechamiento de este tipo de energía, dado que la Península ofrece emplazamientos con gran potencial. Actualmente, la Comunidad Autónoma con mayor potencia eólica instalada es Castilla y León, con 5.560 MW, seguida por Castilla-La Mancha, Galicia, y Andalucía, según el estudio realizado por la Asociación Empresarial Eólica (AEE) [4].



FIGURA 1. PARQUE EÓLICO EN GALICIA, ESPAÑA

Sin embargo, uno de los principales problemas que presenta esta fuente de energía es la naturaleza aleatoria del viento, suponiendo un inconveniente a la hora de integrar la energía generada a la red eléctrica. Este problema radica en que no podemos conocer el comportamiento del viento, y por tanto se hace necesario dotar a los aerogeneradores de medidas de seguridad

ante posibles cambios bruscos de viento, como es el caso de los huecos de tensión, donde se produce una disminución brusca de la tensión y una vuelta rápida a los valores normales que obliga a desconectarlos de la red, causando el corte en la producción [5]. Lo mismo sucede en el caso contrario, cuando la velocidad del viento es muy elevada y supera las especificaciones del aerogenerador, también es necesario desconectarlo de la red o modificar la inclinación de las aspas para evitar que giren y puedan dañar la estructura, haciendo descender la producción eléctrica.

Para comprender la raíz de este problema, se hace necesario conocer más acerca de la energía eólica y su aprovechamiento.

1.2. PLANTEAMIENTO

1.2.1. ENERGÍA EÓLICA

DEFINICIÓN

La energía eólica es la energía que se obtiene gracias al viento, y por consiguiente, gracias al Sol. Esto es porque, como la gran parte de fuentes energéticas, la energía eólica tiene su origen en la radiación solar, ya que ésta provoca el calentamiento de masas de aire que, en función de agentes externos como la nubosidad o la orografía, se calentarán más o menos. La diferencia de presión entre estas masas de aire hace que se desplacen, de forma que las masas de aire caliente ascienden ocupando su lugar masas de aire frío adyacentes, generando así corrientes de aire, o lo que denominamos comúnmente como viento.

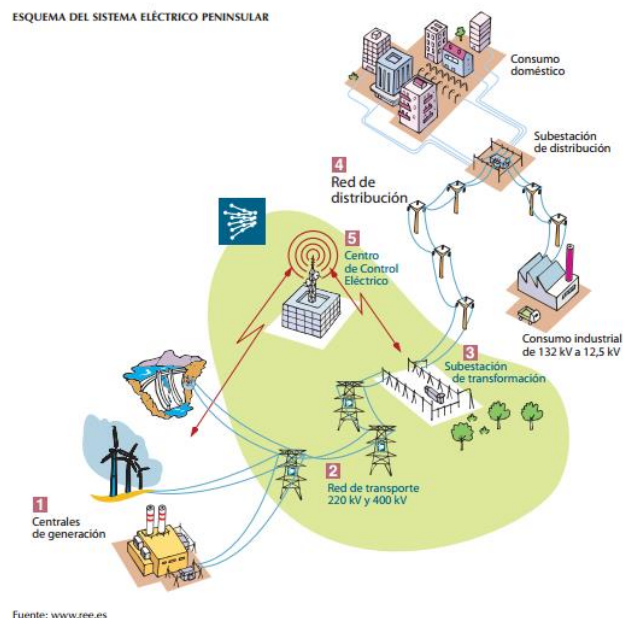


FIGURA 2. ESQUEMA DEL SISTEMA ELÉCTRICO PENINSULAR. [6]

CÓMO SE OBTIENE

Para poder aprovechar la energía eólica son necesarios los aerogeneradores. Los aerogeneradores son molinos de entre 40-50 m de altura que se orientan hacia la dirección en la que sopla el viento. Están compuestos por un rotor al que van acopladas 2-3 aspas de entre 25-50 m, que pueden pesar más de 900 kg cada una. Estas aspas reciben la fuerza del viento, haciendo girar la hélice del aerogenerador transformándose la energía eólica en energía cinética de rotación. El eje de rotación va unido a un multiplicador que aumenta la velocidad de rotación para pasar de una velocidad de aspas de unas 60 rpm a una velocidad de entrada al generador de entre 1500-2000 rpm. El rotor del generador, que va acoplado con el eje de rotación, transformará entonces este movimiento en electricidad, transportándolo a través de conductores hasta la subestación de distribución que la hará llegar al usuario final.




FIGURA 3. PARTES DE UN AEROGENERADOR. [7]

CURVA POTENCIA-VELOCIDAD

La relación entre la potencia eléctrica generada por el aerogenerador y la velocidad del viento que incide horizontalmente en la turbina viene representada por la curva de potencia, que tiene la forma de la Figura 4. En esta curva puede verse que los aerogeneradores necesitan una velocidad de viento mínima de 3-5 m/s para producir potencia eléctrica, es lo que se conoce como velocidad de arranque. A partir de esa velocidad, según aumenta el viento la potencia crece de forma exponencial hasta velocidades de viento de 13-15 m/s, donde la potencia generada permanece estable en el valor nominal para el que está diseñado aunque aumente el viento. Si el viento alcanza los 22-25 m/s se parará el aerogenerador para proteger el rotor de velocidades tan elevadas, es lo que se conoce como velocidad de corte.

La Figura 4 muestra un ejemplo real de un aerogenerador Gamesa 2.5 MW. Por la forma que describe la curva, se puede ver que la mayor variación de potencia generada se da para velocidades de 4 a 13 m/s aproximadamente, y que un mínimo incremento en la velocidad del

viento produce un gran incremento en la potencia generada, por lo que ésta es muy sensible ante variaciones de viento, siendo necesario controlar este factor para evitar que el molino se rompa.




FIGURA 4. CURVA DE POTENCIA DE UN AEROGENERADOR. [8]

Además, la Figura 5 muestra las características de este aerogenerador Gamesa 2.5 MW cuya curva de potencia se ha mostrado en la Figura 4.

GAMESA 2.5 MW

	G106-2.5 MW	G114-2.5 MW	G126-2.5 MW
ROTOR			
Diametro	106 m	114 m	126 m
Área de barrido	8.825 m ²	10.207 m ²	12.469 m ²
Velocidad de giro	7,7 - 14,6 rpm	7,7 - 14,6 rpm	7,1 - 12,9 rpm
PALAS			
Número de palas	3	3	3
Longitud	52 m	56 m	62 m
Perfil	Gamesa	Gamesa	Gamesa
Material	Fibra de vidrio reforzada con resina de epoxy o poliéster	Fibra de vidrio reforzada con resina de epoxy o poliéster	Fibra de vidrio reforzada con resina de epoxy o poliéster
TORRE			
Tipo	Modular	Modular	Modular
Altura	72, 80, 93 m y según emplazamiento	80, 93, 125 m y según emplazamiento	84, 102, 129 m y según emplazamiento

(a)

MULTIPLICADORA			
Tipo	2 etapas planetarias 1 etapa de ejes paralelos	2 etapas planetarias 1 etapa de ejes paralelos	2 etapas planetarias 1 etapa de ejes paralelos
Ratio	1:129.7 (50 Hz) 1:103.8 (60 Hz)	1:129.7 (50 Hz) 1:103.8 (60 Hz)	1:98 (50 Hz) 1:118 (60 Hz)
GENERADOR			
Tipo	generador doblemente alimentado	generador doblemente alimentado	generador doblemente alimentado
Potencia nominal	2.5 MW	2.5 MW	2.5 MW
Tensión	690 V AC	690 V AC	690 V AC
Frecuencia	50 Hz/60 Hz	50 Hz/60 Hz	50 Hz/60 Hz
Clase de protección	IP 54	IP 54	IP 54
Factor de potencia	0.95 CAP-0.95 IND en todo el rango de potencias*	0.95 CAP-0.95 IND en todo el rango de potencias*	0.95 CAP-0.95 IND en todo el rango de potencias*

(b)

FIGURA 5. ESPECIFICACIONES AEROGENERADOR GAMESA 2.5 MW. [8]

VENTAJAS Y DESVENTAJAS DE LA ENERGÍA EÓLICA

Entre las ventajas que ofrece esta fuente de energía cabe destacar que es inagotable ya que en torno al 1-2% de la energía solar se convierte en viento, además es una energía que no contamina el medio ya que los molinos de viento no requieren que exista un proceso de combustión o una etapa de transformación térmica para funcionar ni tampoco producen emisiones, y su emplazamiento es menos complejo puesto que su mayor ocupación tiene lugar en vertical y no impide sacar partido al resto de tierras a su alrededor [9].

Por otro lado, la energía eólica ayuda a reducir los costes de la energía eléctrica (frenando además el agotamiento de los combustibles fósiles), tiene un bajo coste operacional puesto que apenas necesita mantenimiento, y supone mayor demanda de empleo en el sector, tanto en la parte de investigación como en la parte de fabricación, instalación, mantenimiento y soporte, para contribuir a su desarrollo y tratar de aprovechar al máximo el enorme potencial que posee esta fuente de energía.

Sin embargo, existen también ciertos inconvenientes que hay que conocer. En primer lugar, este tipo de energía no está aún tan desarrollada como para competir con las fuentes energéticas convencionales, principalmente por la gran inversión inicial que requiere, además de la pérdida de beneficios que puede suponer dedicar un terreno para su instalación en vez de darle otros usos como ganadería o agricultura. Otro hecho que se debe tener en cuenta es que su situación debe ser cuidadosamente estudiada puesto que puede traer problemas debido al ruido de las turbinas, problemas de impacto visual o poner en peligro la vida de las aves que habitan el entorno, es decir, para poder construir un parque eólico es necesario tener una declaración de impacto ambiental (DIA) positiva.

Finalmente, el mayor de sus inconvenientes, y al que se trata de hacer frente en cierta medida con este trabajo, es que se trata de una energía que no se produce de manera constante dado el

carácter variable e impredecible del viento, y que hasta ahora no puede ser almacenada, por lo que obliga a depender de otra fuente de energía convencional a la que recurrir cuando los aerogeneradores no estén produciendo. Este aspecto es visto en mayor detalle en el siguiente apartado.

1.2.2. REPERCUSIÓN DE LA ENERGÍA EÓLICA EN LA RED ELÉCTRICA

Ahora que ya es conocido el carácter del viento y cómo afecta su velocidad a la potencia eléctrica generada por los aerogeneradores (Curva P-V de la Figura 4), se entiende que la energía que van a producir los aerogeneradores se va a caracterizar por no ser constante, ya que dependiendo de la intensidad de viento en cada instante puede generarse alta o baja potencia, incluso pueden llegar a producirse huecos de tensión, causados por un cortocircuito en el sistema, que corten el suministro eléctrico durante un corto periodo de tiempo.

Otro hecho que ya se ha comentado, es que no existe una forma de gestionar la producción eléctrica generada en los aerogeneradores, ya que toda la cantidad de potencia que pueda ser generada cuando el viento se encuentra entre las velocidades de arranque y de corte se va a generar, sin posibilidad de aumentarla, almacenarla ni reducirla.

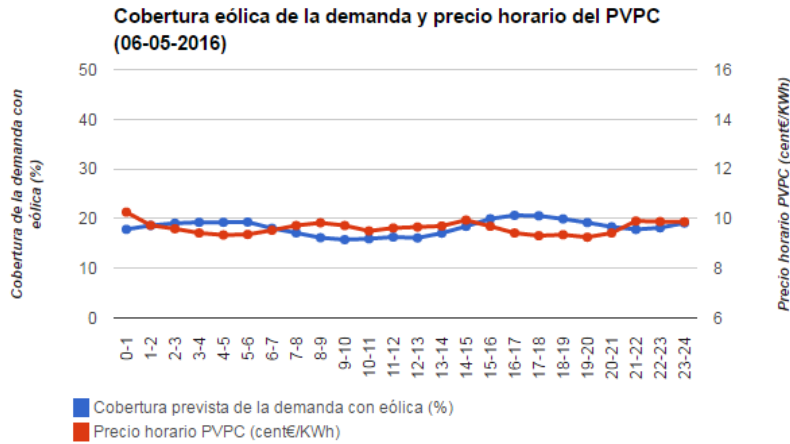
Este comportamiento de la energía eléctrica producida mediante energía eólica hace necesario depender de una reserva de generación eléctrica suficiente que sí pueda ser gestionada, como es la Red Eléctrica, y que pueda responder de forma inmediata para salvar los inconvenientes de la generación eólica y mantener la estabilidad del Sistema Eléctrico.

Dado que, por el momento, la energía eléctrica generada mediante energía eólica y la propia de la Red Eléctrica deben convivir, resulta interesante conocer en qué medida cubre cada una de ellas la demanda eléctrica y cómo afecta la energía eólica a los precios de la luz.


Para empezar, se van a mostrar dos situaciones opuestas que reflejan de forma gráfica cuál ha sido el porcentaje de demanda de energía eléctrica que ha sido cubierta con energía eólica en España, frente al precio horario PVPC (Precio Voluntario para el Pequeño Consumidor [10], precio horario de la energía eléctrica en la nueva forma de facturación de la electricidad, en cent€/kWh) en dos días consecutivos.

Estas dos gráficas de la Figura 6 ilustran la forma en que la energía eólica contribuye a disminuir el precio de la facturación de la luz (determinada con el PVPC). En ambas representaciones puede verse que en las horas en que hay más viento útil la producción de energía eléctrica debida a energía eólica es mayor, el PVPC disminuye y el consumo eléctrico es más barato que cuando el viento no es tan aprovechable y es necesario consumir energía eléctrica convencional.

Esto es así porque al ser el viento un recurso de coste nulo y de coste de generación bajo, este tipo de energía es más barata que las tecnologías que requieren emplear combustibles fósiles, por tanto, cuanta más demanda eléctrica pueda cubrirse con energía eólica menor es el precio de la luz y menos se contamina.



(a)



(b)

FIGURA 6. COBERTURA EÓLICA DE LA DEMANDA Y PRECIO HORARIO DEL PVPC. (A) 06/05/16 Y (B) 07/05/16 [4]

Los mejores datos registrados de producción eólica en España corresponden a 2013, cuando el viento constituyó la primera fuente de producción de energía eléctrica, generando suficiente energía para abastecer al 90% de los hogares españoles [11]. Sin embargo, la energía eólica descendió en 2015 al tercer puesto en energía generada para cubrir la demanda eléctrica peninsular (19%), tras la energía nuclear (22%) y el carbón (20%), debido a las altas temperaturas registradas ese año y a la paralización del sector y de la potencia instalada debido a la reforma del sistema eléctrico [12]. No obstante, se consiguió reducir el precio medio anual del mercado eléctrico en un 23.8%, suponiendo un ahorro de 1.700 millones de euros.

La contribución de cada fuente energética a la cobertura de la demanda eléctrica peninsular para el año 2015 puede verse de forma gráfica en la Figura 7:




FIGURA 7. COBERTURA DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN 2015. [13]

Según la previsión de la evolución energética española reflejada en el documento de Planificación Energética del Ministerio de Industria, Turismo y Comercio, se espera que la potencia instalada en 2020 crezca a los 29.479 MW [14], pero en el periodo 2013-2015 la instalación de parques eólicos se ha frenado considerablemente, teniendo a finales de 2015 una potencia instalada de 22.899 MW que difícilmente permite alcanzar el objetivo fijado para 2020. A pesar de eso, las cifras en esta mitad de 2016 indican una recuperación en la producción eólica cubriendo el 27% de la demanda en el mes de enero, lo cual puede indicar que, a medida que se desarrolle cada vez más este tipo de energía renovable, pudiera hacerse realidad que la energía eólica fuera la fuente principal de generación eléctrica en España.

1.2.3. ENERGÍA EÓLICA EN ESPAÑA

Según recogen las estadísticas, el porcentaje de potencia eólica instalada a nivel mundial está en continuo crecimiento. A finales de 2015 el total de potencia eólica instalada era de 432 GW [15], superiores a los 369 GW que se tenían a finales de 2014 [16]. De esos 432 GW, 145 GW pertenecen a China, 74 GW a USA, 44 GW a Alemania, 25 GW a India y 23 GW a España, es decir, España se sitúa como el quinto país del mundo y el segundo de Europa en potencia eólica instalada a finales de 2015, siendo las Comunidades Autónomas que más potencia generan Castilla y León (241 parques, 5.561 MW), Castilla-La Mancha (139 parques, 3.807 MW), Andalucía (153 parques, 3.338 MW) y Galicia (161 parques, 3.315 MW). [4]

Toda esta energía eólica proviene generalmente de parques eólicos, aunque cabe distinguir dos tipos de parques en función de su localización. A la energía eólica producida por el viento terrestre se le conoce como energía eólica "onshore", al contrario de la energía eólica "offshore" que hace

referencia a energía generada en los parques eólicos marinos. Hasta ahora la energía eólica se está obteniendo principalmente de parques eólicos terrestres, aunque cada vez son más las compañías que apuestan por los parques eólicos marinos cuando se hace posible su instalación.

PARQUES EÓLICOS MARINOS EN ESPAÑA

La instalación de un parque eólico marino se encuentra condicionada por la localización geográfica principalmente, y debe tener en cuenta múltiples factores que afectan a su diseño, siendo éste un caso de estudio que genera cierta complejidad. Para entender la problemática de su diseño, y a la vez justificar las ventajas de estas instalaciones, se va a explicar más acerca de esta tipología de parques.

Los aerogeneradores que componen los parques marinos requieren colocarse a una distancia mínima de la costa de 3 km, desde donde transportan la energía generada hacia la costa mediante cables enterrados en el fondo del mar. Aunque su instalación y mantenimiento es más caro, se compensa con una vida útil de las turbinas mayor, además de suponer una gran opción para aumentar la potencia instalada debido al potencial del viento marino, dado que al no existir obstáculos en la superficie del mar el viento no presenta tantas variaciones y esa constancia hace que gran parte del viento pueda emplearse para generar potencia eléctrica, incluso de forma menos intermitente que con el viento terrestre.

Su principal aplicación sería distribuir a la red eléctrica la energía generada, pero también tienen una posible aplicación aportando energía en el proceso de desalar el agua marina para su consumo, ya que además se evitarían las pérdidas por transporte.

Desafortunadamente, actualmente en España toda la energía eólica producida es “onshore”, es decir, a pesar de estar rodeada de mar, no tiene ningún parque eólico marino. Entre las causas de este hecho se puede citar, por un lado, la negativa de los municipios costeros en aquellos puntos del litoral donde sí sería posible la implantación, como son Huelva, Cádiz y Castellón, y por otro lado la falta de normativa que lo regule, aunque el motivo principal es que las costas españolas se caracterizan por alcanzar en pocos metros una gran profundidad (30-50 m) siendo difícil encontrar ubicaciones que estén cercanas a la costa, pero guardando una distancia de separación mínima de 3 km, y tengan baja profundidad, ya que hasta ahora las tecnologías sólo permiten construir en un máximo de 20 m.

En el Plan de Energías Renovables 2011-2020 uno de los puntos que se estudian para solventar estos inconvenientes es la posibilidad de implantar plataformas flotantes donde situar los aerogeneradores, de forma que pudieran situarse en mejores emplazamientos, más alejados de la costa, sin preocuparse por la profundidad de las aguas ni por el impacto visual.

No obstante, cada vez son más los estudios que se centran en el diseño de estos parques marinos, generalmente aplicando distintos algoritmos bio-inspirados. Un caso de estudio propuesto en [17] tenía como objetivo situar los aerogeneradores de un parque eólico marino para obtener la máxima producción posible empleando el novedoso algoritmo Coral Reefs Optimization y obteniendo buenos resultados para su propósito, por tanto no sería de extrañar que en los próximos años se encontrase la forma de diseñar parques eólicos marinos en las costas españolas.

A falta de desarrollar parques eólicos marinos propios, donde España sí pretende destacar es en la fabricación y exportación de las estructuras de anclaje para los aerogeneradores en el mar que se instalen en parques eólicos marinos de Alemania y Reino Unido. España cuenta con la ventaja de tener amplios conocimientos tecnológicos en el sector gracias al gran despliegue de parques eólicos terrestres, alta capacidad de fabricación, principalmente desde las instalaciones anteriormente dedicadas a la fabricación de navíos, y accesibilidad al mar que facilita el transporte de los equipos.

ENERGÍA EÓLICA DE MEDIA POTENCIA Y ENERGÍA MINIEÓLICA

Al margen de la gran eólica que componen los núcleos de generación eléctrica, otro avance en el sector eólico que se está desarrollando actualmente en España es la energía eólica de media potencia y la energía minieólica [18], basadas en la generación eléctrica cercana al punto de demanda. Este tipo de generación de energía está pensada para el autoconsumo eléctrico, y por tanto irá conectada a la red de distribución final de baja tensión, evitando las pérdidas en transporte y distribución y aprovechando la infraestructura eléctrica existente.

Las turbinas empleadas en este tipo de energía están por debajo de las decenas de kilovatios (minieólica) para aplicaciones domésticas como urbanizaciones o zonas rurales, y entre los 10 kW y los 100 kW (media potencia) para sector industrial [19], agropecuario o grandes infraestructuras públicas o de servicios.

Estas aplicaciones presentan menores inconvenientes en su instalación y suponen una gran ventaja en zonas donde la energía eólica de gran potencia no puede instalarse, además de ayudar a reducir los costes de la factura eléctrica.

Aunque en España aún no está regulado, en ciertos países se promueve este tipo de energías a través del principio de “net metering” [20], que permite consumir la energía generada en cualquier momento a pesar de que ésta no pueda ser almacenada, gracias a que la energía generada sobrante se vierte a la red eléctrica y un contador bidireccional permite descontar de la energía de la red eléctrica consumida la parte correspondiente a la energía vertida en la red. Por tanto éste podría ser uno de los próximos objetivos a implantar para promover el consumo de energía eólica en España.

LÍNEAS FUTURAS DE LA ENERGÍA EÓLICA EN ESPAÑA

Como se ha podido ver en [4], el potencial que la energía eólica puede ofrecer a España es muy alto, a finales de 2015 la potencia instalada ha sido de 23.025 MW, con una producción eléctrica de 47.704 GWh y cubriendo el 19.4% de la demanda eléctrica. Es un sector que encuentra aún en vías de desarrollo, recibiendo una inversión en I+D de 85,5 millones de euros anuales y dando empleo a más de 20.000 personas. Además es el tercer país mundial en exportación del sector eólico, con un beneficio de 2.237 millones de euros, y supone el 0.24% del PIB [14].

En cuanto a la evolución del sector eólico en España, algunos de los objetivos recogidos en el PER 2011-2020 [21] para este horizonte son:

- Desarrollo de aerogeneradores con potencia unitaria en el rango de los 5 a 10 MW para eólica terrestre y de 10 a 20 MW para eólica marina.

- Reducir los costes de generación de energía eólica onshore de gran potencia de 5.9-9.1 c€/kWh (según las horas de funcionamiento) a 4.6-7.1 c€/kWh.
- Propuesta de un marco retributivo estable y predecible que incentive el uso de energía eólica, obteniendo una rentabilidad acorde a las inversiones eólicas.
- Mejorar la capacidad de integración de las energías renovables en el sistema.
- Mejora de la fiabilidad, conexión a la red, ruidos y estructura, para la eólica de pequeña potencia.
- Establecer un plan de retribución económica que incentive las instalaciones eólicas de pequeña potencia (<100 kW).
- Reducir la curva de demanda eléctrica mediante un comportamiento más consciente del usuario final.
- Revisión del Procedimiento de Operación para asegurar las prestaciones, seguridad y capacidad de los generadores eólicos que sustituyen a generadores síncronos.
- Realizar mejoras tecnológicas y de rendimiento de los parques eólicos terrestres existentes (repotenciación), así como fomentar los proyectos de Investigación, Desarrollo, innovación y demostración.
- Fomentar el desarrollo de la eólica offshore facilitando el procedimiento administrativo para instalaciones eólicas marinas de I+D+i+d hasta 30 MW y 3 máquinas. Reducir las barreras administrativas y promover subvenciones en proyectos de esta índole.
- Alcanzar una potencia eólica acumulada en 2020 de 35.000 MW en tierra (34.700 W de media y gran potencia, y 300 MW de pequeña potencia), y 750 MW de eólica marina.
- Alcanzar una producción eléctrica debida a energía eólica en 2020 de 73.500 GWh.

1.3. OBJETIVOS

1.3.1. MOTIVACIÓN

Como ya se ha comentado acerca de la energía eólica, la potencia eléctrica que generan los aerogeneradores se caracteriza principalmente por su intermitencia, ya que depende de la velocidad del viento en cada momento, y por la imposibilidad de gestionarla y almacenarla, al menos no de forma económicamente rentable.

Esto genera problemas en su integración en el sistema eléctrico, ya que no supone una solución estable al estar limitada por la variabilidad del viento y la sensibilidad de los aerogeneradores, llegando a detenerse la generación eléctrica cuando se detectan problemas tales como los huecos de tensión, que obligan a desconectarlos de la red. Por este motivo, actualmente es necesario

disponer a la par de una fuente de generación eléctrica que sí pueda ser gestionada y esté disponible en todo momento para salvar estos inconvenientes que presenta la energía eólica.

Uno de los puntos fuertes de investigación en el sector es la mejora de los aerogeneradores para permitir un mayor grado de integración de la energía eólica en la red sin comprometer su seguridad. Además, desde hace algunos años España cuenta con el Centro de Control de Energías Renovables (Cecre [22]), que es el primer centro del mundo donde se controla la generación de los productores de energías renovables, principalmente eólicos, para optimizar su integración en el sistema eléctrico. Para ello cuenta con la situación de distintos puntos de control que permiten obtener información en tiempo real de los parques eólicos a los que están conectados, supervisando el comportamiento de los aerogeneradores y obteniendo información del estado o la producción energética.




FIGURA 8. DISPOSICIÓN DEL CECRE Y LOS CENTROS DE CONTROL, ASÍ COMO PARQUES DE GENERACIÓN Y SUBESTACIONES. [22]

Estos datos se analizan en tiempo real a través de potentes herramientas que determinan si es posible integrar la energía generada en la red sin comprometer la seguridad del suministro, pudiendo también anticiparse a imprevistos y responder de forma inmediata mediante ejecución de instrucciones para mantener al sistema en estado seguro.



FIGURA 9. COMUNICACIÓN ENTRE EL CECRE Y LOS DISTINTOS CENTROS DE CONTROL. [22]

A través del CECRE se pueden emitir órdenes a los centros de control para proteger al sistema eléctrico de perturbaciones, como puede ser una crítica disminución de la producción eólica, o por el contrario un exceso de producción, ya sea por generar sobrecargas en la red de transporte o de distribución o por la escasa demanda en esos momentos.

Ambas situaciones vienen dadas por la imposibilidad de conocer la evolución que tendrá la producción eléctrica en los parques, ya que todas las predicciones de potencia eléctrica generada llevan consigo un error de predicción. Este es otro de los retos a los que debe hacer frente el sector eólico, tratar de predecir velocidades de viento futuras y minimizar el error cometido en la predicción, con vistas a poder conocer de antemano los medios con los que se va a tener que satisfacer la demanda eléctrica. Este es también el objetivo principal de este Trabajo Fin de Máster, en concreto predecir el máximo que tomará la velocidad del viento en las próximas horas para conocer la capacidad de generación eólica que se tendrá.

1.3.2. PREDICCIÓN

Ahora que se conocen las características y limitaciones de la energía eólica y su dependencia de otra fuente de energía convencional, como son las centrales eléctricas, para cubrir la demanda eléctrica cuando la producción debida al viento no es capaz de satisfacerla, puede tenerse una idea de la ventaja que supondría ser capaces de predecir la fuerza que va a tener el viento en situaciones futuras.

A partir de la predicción de la demanda eléctrica, las centrales eléctricas son capaces de planificar la energía que va a ser necesario generar. Ahora a esta planificación se le añade un factor menos previsible, con el desarrollo del sector eólico entra en juego la necesidad de predecir la energía que va a poderse generar gracias a los parques eólicos para poder así gestionar ambas fuentes energéticas.

La posibilidad de conocer cuánta potencia eléctrica va a generarse mediante energía eólica en cierto momento trae numerosos avances que mejoran su integración en la red eléctrica y contribuyen a obtener mayor aprovechamiento del potencial que puede ofrecer esta fuente de energía renovable.

Por un lado, el operador del sistema, en este caso Red Eléctrica de España (REE), podría garantizar un suministro eléctrico estable y seguro si conociese de antemano la cantidad de potencia eléctrica debida al viento que se va a verter a la red para, según la demanda prevista, planificar la potencia que va a ser necesario generar desde las centrales convencionales. De esta forma la energía total generada sería cercana a la demandada y no generaría muchos excesos de producción.

Por otro lado, las empresas propietarias de los parques eólicos pueden tomar mejores decisiones en el mercado eléctrico si conocen la potencia que son capaces de generar sus parques, por tanto cuanto más precisa pueda ser la predicción de generación mejores decisiones pueden tomar. Además, conocer los momentos donde la producción va a ser baja puede ser útil para saber cuándo conviene realizar las labores de mantenimiento de los parques eólicos.

Como se puede ver, la predicción eólica resulta interesante en diferentes ámbitos:

- A nivel económico, porque ajustando la cantidad de energía que va a ser necesario producir desde otras fuentes de generación ajenas a la eólica para satisfacer la curva de demanda, se reducen los costes de disponer de esta reserva, aunque se debe tener en cuenta posibles desvíos en la producción eólica.
Además, al mejorar la predicción de energía generada en los parques eólicos se reducen los costes de penalizaciones por verter a la red mayor energía de la programada.
- A nivel ambiental, porque siendo más precisos en la predicción se evitará generar más energía de la necesaria y por tanto controlar el consumo de combustibles y la expulsión de gases contaminantes al medioambiente.
- A nivel de integración en el sistema eléctrico, porque el operador del sistema puede conocer si en algún elemento de la red se están produciendo anomalías como desconexiones por huecos de tensión o congestiones en las líneas, y mantener el equilibrio entre energía demandada y consumida ofreciendo suministro de forma estable y segura.

1.3.3. APLICACIÓN DE TÉCNICAS MACHINE LEARNING

Brevemente se puede decir que el objetivo de este Trabajo Fin de Máster es llevar a cabo la predicción a corto plazo de extremos de viento realizando una comparativa en términos de error de predicción en función del modelo empleado para la predicción. El planteamiento es partir inicialmente de un modelo constituido exclusivamente por variables de velocidad de viento, incluir posteriormente en él variables meteorológicas de distintas estaciones de medida, y finalmente seleccionar el subconjunto óptimo de estas características que permite mantener o reducir el error de predicción. Los datos de partida utilizados en este estudio son los datos de velocidad de viento recogidos cada hora durante 17 años en el parque eólico de Peñaparda, Salamanca, mientras que las variables meteorológicas han sido obtenidas del ERA-Interim, para ese periodo, y pertenecen a cuatro estaciones de medida cercanas al parque. Estos datos se verán en detalle en el siguiente capítulo.

Para este propósito se van a emplear distintas técnicas “machine learning” o de aprendizaje de máquinas, pertenecientes a la rama de la inteligencia artificial, aplicadas a los problemas que se desean resolver, en este caso tanto a la predicción de extremos de viento como al problema de selección de características o FSP (Feature Selection Problem).

El motivo que lleva a emplear estas técnicas comienza por la popularidad que han adquirido a lo largo de estos últimos años. Estas técnicas permiten analizar un conjunto de datos para aprender de ellos sin necesidad de que exista una labor previa de programación que guíe a la máquina en cómo debe tratar los datos, sino que se trata de que ésta aprenda por sí sola, detectando ciertos patrones o características que no son perceptibles por el ser humano. Esto permite aplicarlas en problemas donde se dispone de resultados pasados pero se desconoce cómo aprovecharlos para tratar los datos actuales, por tanto corresponde a la máquina aprender de estos datos previos conocidos para crear un modelo capaz de analizar grandes y complejas cantidades de datos y ofrecer resultados precisos, en relativamente cortos periodos de tiempo, que permitan tomar decisiones en tiempo real sin necesidad de intervención humana [23].

Hoy en día, existe una amplia variedad de sectores donde son de aplicación estas técnicas de aprendizaje automático, como pueden ser el sector energético, la medicina, las comunicaciones o el sector financiero. En concreto, se pueden citar estos estudios donde han sido empleadas con éxito para resolver problemas de: predicción de fenómenos atmosféricos [24], detección de anomalías tales como cáncer [25], asignación de frecuencias o planificación del espectro [26], o predicción de quiebras empresariales y detección de fraude [27], aunque es posible encontrar múltiples artículos donde se emplean estas técnicas de aprendizaje para distintas aplicaciones.

Es más, estas técnicas están presentes en el día a día aunque pasen desapercibidas, es el caso del marketing online, orientado a las búsquedas que ha realizado anteriormente el usuario [28], o las técnicas de comparación y búsqueda del precio de mercado que emplean en Amazon para garantizar el precio más bajo en sus productos [29].

En el caso de este Trabajo Fin de Máster el problema que se plantea es un problema de predicción de máximos de viento. Existen distintos estudios que han utilizado técnicas de machine learning

para enfrentarse a la problemática de la predicción. Principalmente se han empleado máquinas de vectores soporte para regresión (SVMr) [30], que es una técnica perteneciente a la computación neuronal, obteniéndose buenos resultados de predicción, aunque generalmente son empleadas para predecir la velocidad media de viento a corto plazo, desde unos minutos a unas pocas horas, con vistas a obtener la predicción de potencia total producida en el parque eólico [31].

En otros estudios, se realizan comparativas del rendimiento de distintas técnicas al aplicarlas a la resolución de un mismo problema, como sucede en [31] y en [32], donde compara la técnica SVMr con otra técnica de computación neuronal como son los perceptrones multicapa (MLPs).

Aunque a la vista de estos estudios las SVMr han demostrado su aptitud para ofrecer resultados de predicción de velocidad precisos, también existen estudios que emplean redes neuronales artificiales para este propósito, como sucede en [33].

El éxito que han tenido estas técnicas de inteligencia artificial aplicadas a problemas de predicción de velocidad de viento hace que surjan cada vez más nuevos estudios que prueban técnicas más novedosas, tratan de mejorar el rendimiento de las técnicas iniciales o incluso combinan ciertas técnicas para obtener mejores resultados. Además, estos algoritmos se han combinado con modelos meteorológicos con vistas a optimizar la predicción. Esto hace que puedan incluirse en el modelo de predicción numerosas variables meteorológicas, cuyo rango puede verse incrementado aún más si se tienen en cuenta distintas estaciones de medida, recogiendo el mismo conjunto de variables en diferentes localizaciones o altitudes. Este planteamiento lleva a un nuevo problema conocido en inteligencia artificial como Problema de Selección de Características (FSP), basado en obtener a través de cierto criterio el conjunto reducido de características de entrada al algoritmo que iguala o mejora los resultados de predicción, ya que en el conjunto de variables original pueden existir variables que no sean relevantes en el problema y puedan ser descartadas. Esta problemática también será tratada en este trabajo, por lo que posteriormente se entrará en más detalle.

Esta selección de características puede llevarse a cabo de forma aleatoria bajo algún criterio [33], pero se ha demostrado que los resultados mejoran si se realiza un análisis más exhaustivo empleando otras técnicas. En este contexto existen estudios que aplican técnicas como el algoritmo Particle Swarm Optimization, perteneciente a la computación evolutiva [34], un algoritmo genético [35], también basado en los algoritmos evolutivos, o un novedoso algoritmo denominado Coral Reefs Optimization [36], algoritmo híbrido entre algoritmo evolutivo y algoritmo iterativo constructivo, para seleccionar las mejores características de entrada. Además, este último ha sido mejorado posteriormente incorporando operadores propios del algoritmo Harmony Search en la fase reproductiva del CRO, dando lugar a un algoritmo híbrido CRO-HS [37], que presenta menor error que la aplicación individual de los algoritmos CRO o HS.

Estos estudios coinciden en que se ha empleado además una red neuronal entrenada mediante el algoritmo Extreme Learning Machine tanto en la fase de selección de características, como posteriormente para evaluar la aptitud de las características seleccionadas y obtener los resultados finales de predicción. El éxito de este algoritmo se debe a poder disponer de un método rápido y preciso de entrenar una red neuronal para conocer los resultados tanto al problema de selección (FSP) como al problema de predicción de velocidad de viento.

Dada la multitud de estudios que apuestan por las técnicas de machine learning para resolver este tipo de problemática compleja que escapa de las técnicas tradicionales, y habiendo respondido bien ante problemas de predicción de velocidad o de velocidad media a corto plazo, se ha optado por emplear éstas para el propósito que se persigue. En concreto, para el problema de predicción de extremos de viento se emplearán las redes neuronales artificiales (ANN) entrenadas mediante el algoritmo Extreme Learning Machine (ELM) por ser un algoritmo rápido, con baja carga computacional, que ha demostrado ofrecer buenos resultados, y, dado que en algún momento de la parte experimental se incorporarán al modelo variables meteorológicas, se hará frente al problema de selección de características (FSP) empleando un algoritmo genético para la selección, que además haga uso de una ELM para evaluar la el error de predicción obtenido con cada subconjunto de características, y también para obtener los resultados de predicción finales para el subconjunto seleccionado.

En el siguiente apartado se profundizará en la base teórica donde se sustentan estas técnicas de soft-computing empleadas en la parte experimental de este Trabajo Fin de Máster, así como su implementación en la herramienta de Matlab.

2. MÉTODOS

2.1. INTRODUCCIÓN AL SOFT COMPUTING

La Inteligencia Computacional o Soft-Computing es una rama de la inteligencia artificial que engloba a un conjunto de técnicas empleadas para resolver problemas complejos que no pueden resolverse por métodos tradicionales, generalmente problemas de clasificación, regresión, control, optimización, etc [38]. Entre estas técnicas de Inteligencia Computacional se encuentran las Redes Neuronales y la Computación Evolutiva.

Las redes neuronales son técnicas inspiradas en las neuronas del cerebro. Se usan principalmente en problemas de clasificación supervisada o de regresión, y están relacionadas con el aprendizaje automático o técnicas de *machine learning*. El término *Machine Learning* hace referencia al uso de técnicas de Inteligencia Artificial cuyo objetivo es dotar a las máquinas de “inteligencia” de forma que, a partir de un entrenamiento basado en ejemplos, sea capaz de generalizar comportamientos. De esta forma, una vez se haya entrenado un modelo, éste dispondrá del conocimiento necesario, fruto de su experiencia con los ejemplos, para predecir la salida a futuras entradas.

Por otro lado, las técnicas de Computación Evolutiva son algoritmos bio-inspirados que se usan principalmente para optimización de sistemas, problemas discretos y continuos y clustering [38]. Dentro de estas técnicas se encuentran los Algoritmos Genéticos, basados en la evolución de la población a lo largo de varias generaciones, siguiendo los principios de selección natural y supervivencia definidos por Darwin.

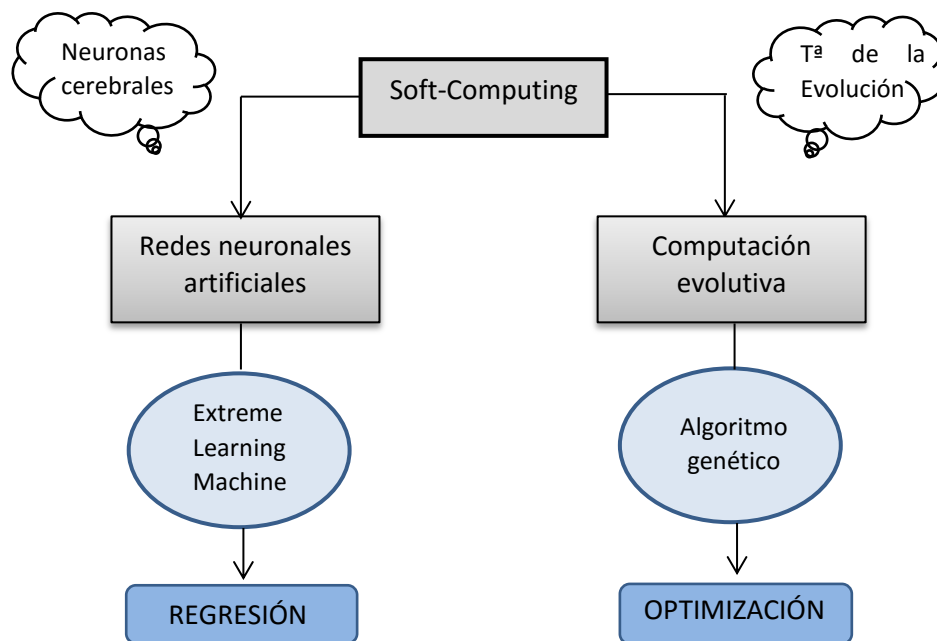


FIGURA 10. TÉCNICAS SOFT-COMPUTING EMPLEADAS EN ESTE TRABAJO.

A lo largo de este apartado se va a exponer la base teórica donde se sustentan las técnicas anteriormente citadas, comenzando por la computación neuronal empleada para resolver problemas de regresión, y continuando con la computación evolutiva, empleada para optimizar los resultados de predicción obtenidos con la red neuronal. Así, en primer lugar se dará a conocer en qué se basan, cómo funcionan y qué aplicaciones tienen las redes neuronales, entrando en detalle en un algoritmo neuronal, Extreme Learning Machine (ELM), que será el empleado para obtener la predicción de extremos de viento, y su implementación en la herramienta de software Matlab. Y en segundo lugar, se expondrán las bases de los Algoritmos Evolutivos, particularizando para el caso de un Algoritmo Genético (GA), que será el empleado para optimizar la predicción, explicando su comportamiento y cómo se llevará a cabo su implementación en Matlab.

2.2. REDES NEURONALES

Las redes neuronales artificiales (ANN, Artificial Neural Network) se han definido como un sistema computacional compuesto por elementos de procesamiento interconectados que procesan información de forma conjunta ante entradas externas. Este comportamiento está basado en los sistemas nerviosos, como es el cerebro, y la forma en que los conjuntos de neuronas que lo componen se comunican entre sí generando un impulso nervioso para responder de forma conjunta a un estímulo externo.

Para imitar este comportamiento, las ANNs están compuestas por nodos, que simularían ser las neuronas del cerebro, organizados en distintas capas conectadas entre sí: capa de entrada, una o más capas intermedias llamadas capas de neuronas ocultas y capa de salida. La capa de entrada conecta con las variables de entrada al algoritmo de aprendizaje, por tanto se compondrá de tantos nodos como variables existan, y lo mismo sucede con la última capa y las variables de salida, mientras que el número de capas intermedias y de nodos en cada capa debe ser ajustado en función del problema para obtener buenos resultados.




FIGURA 11. ESTRUCTURA DE UNA RED NEURONAL. [35]

Cada nodo recibe un estímulo de entrada junto con un peso asignado a esa conexión que determinan la función de red o función de entrada a la neurona, normalmente dicha función es una suma ponderada de las entradas con los pesos asociados [39]. Posteriormente, la salida de la función de red se transforma mediante una función de activación, comúnmente de tipo sigmoidea, produciendo una señal de salida que se transmite a otras neuronas.

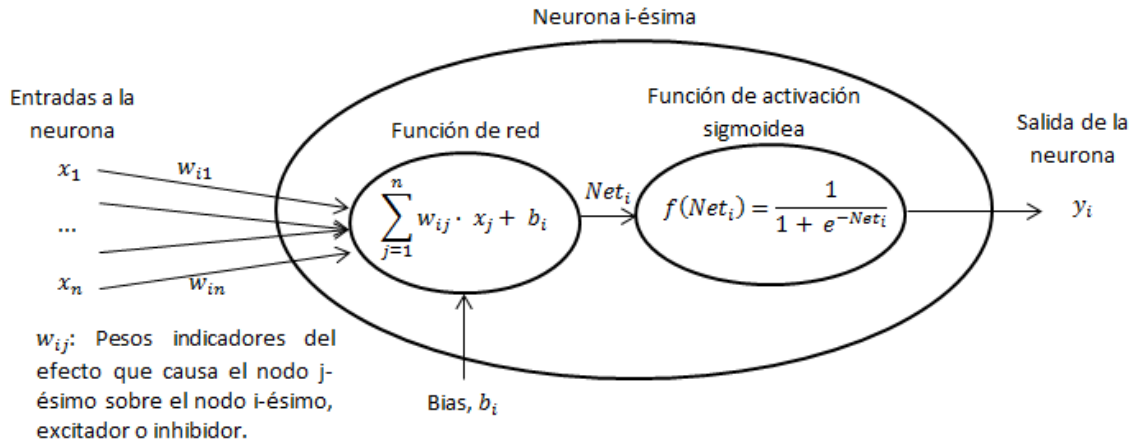


FIGURA 12. ESTRUCTURA DE UNA NEURONA ARTIFICIAL EN IA.

Dado que la intensidad de la señal transmitida vendrá determinada por los pesos asignados a esa conexión, este parámetro es una de las claves para el aprendizaje de la red, junto con el empleo de un número de nodos óptimo. A partir de un conjunto de ejemplos y conociendo la salida deseada, la red debe ser capaz de adaptar su estructura ajustando dichos pesos para obtener un modelo óptimo y generalizado.

No obstante, una red neuronal se debe entrenar de forma específica para una determinada aplicación, de forma que ajuste los pesos de las conexiones neuronales para adaptarlas a ese impulso específico y aprender de ello.

Finalmente, cabe destacar que gracias a su enfoque este tipo de redes le ha ganado ventaja a los ordenadores convencionales a la hora de resolver problemas complejos. Esto se debe a que los ordenadores saben cómo resolver un problema si conocen el conjunto de instrucciones que deben ejecutar para ello, como por ejemplo operaciones aritméticas. Sin embargo, existen problemas cuya solución no puede alcanzarse siguiendo determinados pasos programados de antemano, y ahí es donde entran en juego las redes neuronales, que aprenden según ejemplos pasados y en base a su experiencia son capaces de llegar a una solución precisa [40].

En base a todo lo comentado, puede decirse que las redes neuronales artificiales se caracterizan por:

- Aprendizaje adaptativo y auto-organización: el entrenamiento con ejemplos permite que la estructura neuronal se adapte al problema que deben afrontar y extraiga de su experiencia sus propias reglas a aplicar para llegar a la solución deseada.
- Procesado en paralelo: la organización de las neuronas en capas, y cómo están altamente interconectadas entre sí, posibilita que exista un paralelismo equivalente al que existe en las neuronas cerebrales.
- Generalización: el objetivo de entrenar a una red neuronal es dotarle de cierta experiencia con determinado problema, de forma que al introducir nuevos datos en la red sea capaz de llegar a una solución adecuada.
- Entradas incompletas: la red es capaz de procesar entradas con datos incompletos o con ruido porque extrae las características esenciales de las entradas para obtener la solución deseada y descarta el resto.

2.2.1. REDES SFLN

El tipo de implementación de red neuronal artificial más simple se conoce como “Single Layer Feed-forward Network” (SLFN), y está basada en redes neuronales de tipo “feedforward”, donde la señal viaja hacia delante propagándose sólo a neuronas de la capa siguiente, sin existir ningún tipo de feedback. Este será el tipo de red empleada para este estudio.

La estructura de la red SLFN tiene el siguiente aspecto de la Figura 13, compuesta únicamente por una capa oculta de M neuronas. Según describen Huang et al. en su artículo “Extreme learning machine: Theory and applications” [41], en una red SLFN con M neuronas en la capa oculta y N muestras de entrenamiento $(\mathbf{x}_i, \mathbf{t}_i)$ donde $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$ y $\mathbf{t}_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T \in \mathbb{R}^m$, el resultado de cada neurona de salida de la red SLFN puede modelarse como indica la expresión (1):

$$\mathbf{o}_j = \sum_{i=1}^M \beta_i \cdot f(\mathbf{w}_i \cdot \mathbf{x}_j + b_i), \quad j = 1, \dots, N \quad (1)$$

siendo $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ el vector de pesos que conecta la neurona oculta i -ésima con los nodos de entrada de la red, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ el vector de pesos que conecta la neurona oculta i -ésima con los nodos de salida de la red, b_i el bias de la neurona oculta i -ésima, y $f(\cdot)$ la función de activación.




FIGURA 13. ESTRUCTURA DE UNA RED SLFN.

La técnica de aprendizaje más popular empleada para las redes SLFN es el algoritmo “back propagation”. Inicialmente se fija un número de neuronas de la capa oculta M y se asignan unos pesos de forma aleatoria, y es el algoritmo “back propagation” el que tras cada ciclo de entrenamiento de la red compara la salida obtenida con la salida deseada, propagando posteriormente hacia atrás el error calculado. De esta forma la red va ajustando los pesos de las conexiones para reducir el error de salida, consiguiendo tras múltiples ciclos de entrenamiento ajustar los pesos de forma que a la salida se tenga un error suficientemente pequeño. Para ello, uno de los métodos de entrenamiento que se puede emplear es el método de gradiente descendente, que consiste en obtener una función de error de la red en función del conjunto de pesos y encontrar la configuración de pesos que consigue el mínimo global de la función de error. Para ello, se calcula la dirección de máximo crecimiento de la función de error a través del gradiente, y se actualizan los pesos de la red en el sentido contrario de máximo decrecimiento.

Este procedimiento de entrenamiento y ajuste de pesos de la red conlleva un tiempo de ejecución elevado dada la carga computacional del algoritmo. Por este motivo se propuso en [41] un nuevo algoritmo de entrenamiento de las redes SLFN más sencillo de implementar que consigue obtener resultados precisos mejorando el tiempo de ejecución. Se trata del algoritmo Extreme Learning Machine (ELM) que se verá a continuación.

2.2.2. EXTREME LEARNING MACHINE

Las máquinas de aprendizaje extremo, o Extreme Learning Machines, son un algoritmo de aprendizaje propuesto por Huang [41] para entrenar las redes SLFN reduciendo considerablemente el tiempo de ejecución.

Su principal ventaja es que una técnica machine learning con baja carga computacional, ya que está basada en que asignando los pesos de entrada a la red SLFN de forma aleatoria la red puede ser considerada un sistema lineal y los pesos de salida se pueden obtener con la inversa generalizada de la matriz de salida de la capa oculta. Esto hace que el tiempo empleado para entrenar la red sea relativamente bajo comparado con otras técnicas más complejas, y sin embargo, en muchas ocasiones consigue incluso obtener mejores resultados.

En el apartado anterior se expresó la salida de una neurona de la red SLFN como indica la expresión (1).

Esta salida puede aproximarse al target buscado con error cero (2) si existen β_i , \mathbf{w}_i y b_i tales que cumplan (3):

$$\sum_{j=1}^M \|o_j - t_j\| = 0 \quad (2)$$

$$\sum_{i=1}^M \beta_i \cdot f(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = t_j, \quad j = 1, \dots, N \quad (3)$$

Reescribiendo esta ecuación (3) de forma compacta en (4), la matriz de salida de la capa oculta multiplicada por la matriz de pesos de salida, debe ser igual a la matriz de salida deseada o targets:

$$\mathbf{H}\beta = \mathbf{T} \quad (4)$$

siendo,

$$\mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_M, b_1, \dots, b_M, \mathbf{x}_1, \dots, \mathbf{x}_N) = \begin{bmatrix} f(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \dots & f(\mathbf{w}_M \cdot \mathbf{x}_1 + b_M) \\ \vdots & \ddots & \vdots \\ f(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \dots & f(\mathbf{w}_M \cdot \mathbf{x}_N + b_M) \end{bmatrix}_{N \times M} \quad (5)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m} \quad (6)$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_M^T \end{bmatrix}_{N \times m} \quad (7)$$

Basándose en una serie de teoremas descritos en el artículo [41] (Theorem 2.1 y Theorem 2.2) llegan a la conclusión de que ajustar los parámetros \mathbf{w}_i y b_i en el entrenamiento equivale a encontrar la solución de mínimos cuadrados $\hat{\beta}$ del sistema lineal $\mathbf{H}\beta=\mathbf{T}$, expresado en (8).

$$\|\mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_M, b_1, \dots, b_M)\hat{\beta} - \mathbf{T}\| = \min_{\beta} \|\mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_M, b_1, \dots, b_M)\beta - \mathbf{T}\| \quad (8)$$

Cuando el número de nodos de la capa oculta (M) coincide con el número de muestras de entrenamiento (N), \mathbf{H} es cuadrada e invertible y la red neuronal puede aproximar la salida con error cero. Pero normalmente esto no ocurre porque $N \gg M$. En ese caso la única solución con menor error de entrenamiento y menor norma de mínimos cuadrados está expresada como:

$$\hat{\beta} = \mathbf{H}^{\dagger} \mathbf{T} \quad (9)$$

siendo \mathbf{H}^{\dagger} la inversa generalizada Moore-Penrose de la matriz \mathbf{H} .

Este método es el empleado en el algoritmo ELM, pudiendo resumirse en los siguientes pasos:

- 1- Asignar de forma aleatoria los pesos a las conexiones de entrada a la red, \mathbf{w}_i , y los bias de las neuronas ocultas b_i , $i=1, \dots, M$, siendo M el número de nodos de la capa oculta.
- 2- Calcular la matriz de salida de la capa oculta, H, mediante la ecuación (X).
- 3- Calcular la pseudo-inversa de Moore-Penrose de H.
- 4- Calcular los pesos de salida de la red $\beta=\mathbf{H}^{\dagger}\mathbf{T}$, siendo \mathbf{T} el vector de salida del conjunto de entrenamiento.

De este modo, al entrenar una red neuronal con el algoritmo ELM no será necesario ajustar los pesos de entrada a la red ni los bias de las neuronas de capa oculta, aunque habrá que indicar el número de neuronas que tendrá la capa oculta, M, generalmente probando diferentes valores hasta obtener el resultado deseado.

IMPLEMENTACIÓN DEL ALGORITMO ELM EN MATLAB

Como se ha comentado en el apartado anterior, este tipo de algoritmo de aprendizaje basado en redes neuronales “feedforward” propuesto por Huang [41] ha ganado popularidad gracias a sus buenos resultados como alternativa de entrenamiento de baja carga computacional frente a otros algoritmos más complejos. El objetivo ahora es describir cómo está implementado en la herramienta de Matlab donde se han realizado los experimentos oportunos.

El código empleado en Matlab para implementar el algoritmo Extreme Learning Machine ha sido obtenido de un portal web [42] donde se puede encontrar teoría sobre ELMs, tutoriales y códigos fuente en distintos lenguajes de programación, además de poder escoger entre varios modelos de ELM, desde el algoritmo básico hasta ELMs modificadas para diversas soluciones (Big data, perceptrón multicapa, análisis de proteínas y genomas, clustering, etc).

Para el caso que ocupa este Trabajo Fin de Máster se ha optado por el código de ELM básico en la versión para Matlab.

Dentro de esta librería existen 3 funciones disponibles para descarga, una función genérica de ELM que realiza entrenamiento y test (“elm”), y dos funciones individuales que realizan el entrenamiento y el test por separado (“elm_train” y “elm_predict”) y que permiten guardar el modelo de red entrenado. Dado que el código que presentan las funciones individuales equivale a la función completa, se ha optado por emplear ésta.

La función “elm.m” empleada presenta los siguientes argumentos de entrada y salida detallados en la Tabla 1:

Prototipo: [TrainingTime, TestingTime, TrainingAccuracy, TestingAccuracy] = elm (TrainingData_File, TestingData_File, Elm_Type, NumberofHiddenNeurons, ActivationFunction)	
Argumentos de entrada	
TrainingData_File	Conjunto de datos de entrenamiento, organizados en columnas donde la primera columna sea el Target y el resto los atributos normalizados en el rango [-1,1].
TestingData_File	Conjunto de datos de test o validación, organizados en columnas donde la primera columna sea el Target y el resto los atributos normalizados en el rango [-1,1].
Elm_Type	Tipo de ELM: 0 – Regresión; 1 – Clasificación.
NumberofHiddenNeurons	Número de neuronas en la capa oculta de la red neuronal.
ActivationFunction	Función de activación: ‘sig’ – Función sigmoideal; ‘sin’ – Función seno; ‘hardlim’ – Función Hardlim; ‘tribas’ – Función en base triangular; ‘radbas’ – Función en base radial.

Argumentos de salida	
TrainingTime	Tiempo en segundos empleados en el entrenamiento de la red.
TestingTime	Tiempo en segundos empleados en la predicción.
TrainingAccuracy	Error cometido en el entrenamiento (RMSE).
TestingAccuracy	Error cometido en la predicción (RMSE).

TABLA 1. ARGUMENTOS DE ENTRADA Y SALIDA DE LA FUNCIÓN ELM.

Generalmente, el procedimiento a seguir para obtener el error de predicción con la función ELM es construir primero el conjunto de datos, compuesto por la columna de salida deseada o target sin normalizar y las columnas de atributos normalizados, y hacer la división en los conjuntos de Train y Test, normalmente con un porcentaje en torno al 80-20%, que serán empleados para entrenar la red neuronal y para validar la bondad del modelo entrenado, respectivamente. Estos conjuntos se pasarán como argumentos de entrada a la función ELM, escogiendo a su vez el tipo de ELM para problemas de regresión (“Elm_Type”=0), además de especificar cierto número de nodos en la capa oculta (“NumberofHiddenNeurons”) y cierta función de activación (“ActivationFunction”), que podrán ajustarse hasta obtener buenos resultados de predicción.

Un hecho importante en esta metodología de entrenamiento es que el modelo debe ser capaz de generalizar resultados a partir de ejemplos específicos (conjunto de Train), es decir, debe ser capaz de aproximarse lo mejor posible a la salida buscada cuando se introduzca al algoritmo cualquier otro conjunto de datos distinto al de entrenamiento (conjunto de Test), de forma que el modelo sea capaz de hacer predicciones precisas a partir de datos que nunca ha visto.

Una mala generalización del modelo puede venir causada por problemas de “overfitting” o “underfitting” [43]. “Overfitting” hace referencia a que el modelo se ha adaptado demasiado a los datos del conjunto de Train, teniendo muy buen rendimiento con ese conjunto pero muy malo al introducir nuevos datos, ya que los conocimientos aprendidos no se pueden aplicar al nuevo conjunto. Y “underfitting” hace referencia a un modelo que no ha sido capaz de aprender del conjunto de Train, teniendo mal rendimiento, y por tanto peor rendimiento tendrá con un conjunto nuevo de datos.

Generalmente el más común y problemático es el problema de “overfitting”, cómo evitar entrenar el modelo más de lo necesario para no penalizar su generalización. Para ello hay dos posibles técnicas: emplear validación cruzada o comprobar el rendimiento del modelo con un conjunto de validación o test.

La técnica de validación cruzada o cross-validation es ampliamente utilizada para validar los modelos entrenados en problemas de aprendizaje automático. Está basada en realizar distintas particiones del conjunto de datos (manteniendo la proporción Train-Test (%) en cada partición) y realizar tantas ejecuciones del algoritmo ELM como combinaciones Train-Test se tengan para finalmente calcular la media aritmética de las distintas simulaciones. Este resultado medio tendrá mayor precisión que un resultado obtenido con el método más simple de retención o holdout, donde se ejecuta una única vez el algoritmo y los resultados pueden variar significativamente según cómo haya sido la partición del conjunto de datos.

Principalmente destacan estas formas de validación cruzada [44]:

- Validación cruzada de k-iteraciones (k-fold cross-validation), que divide el conjunto de datos en k subconjuntos consecutivos de igual tamaño y se combinan empleando un subconjunto para test y k-1 subconjuntos para entrenamiento. Es una técnica precisa ya que se prueban k combinaciones Train-Test distintas, pero a su vez implica más carga computacional.




FIGURA 14. EJEMPLO DE VALIDACIÓN CRUZADA DE 4-ITERACIONES.

- Validación cruzada aleatoria, que realiza k divisiones distintas del conjunto de datos, escogiendo posiciones aleatorias para formar cada subconjunto. Tiene la ventaja de que la proporción Train-Test no depende del número de iteraciones, aunque puede suceder que una misma muestra sea escogida en el conjunto de entrenamiento o de test en varias iteraciones.




FIGURA 15. EJEMPLO DE VALIDACIÓN CRUZADA ALEATORIA.

En los experimentos realizados se ha optado por emplear validación cruzada aleatoria ya que este método, al hacer el reparto de entrenamiento y test de forma aleatoria, va a conseguir mayor variedad de ejemplos en cada subconjunto y por tanto mayor representación de todos los datos, contribuyendo a evitar el problema de overfitting de los resultados.

Por otro lado, en cada iteración del algoritmo ELM se va a almacenar el error de predicción cometido, que servirá para obtener el rendimiento del modelo mediante el Root Mean Square Error (RMSE), definido en (10) como:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}} \quad (10)$$

siendo \hat{Y} la salida del algoritmo e Y la salida deseada, y mediante el cuadrado del coeficiente de correlación de Pearson (R^2), descrito en (11), que determina la relación lineal que existe entre la salida del algoritmo y la salida deseada, de tal forma que mejor será la predicción cuanto más se ajusten los datos a la línea de regresión:

$$R^2 = \frac{\sigma_{\hat{Y}Y}^2}{\sigma_{\hat{Y}}^2 \cdot \sigma_Y^2} \quad (11)$$

siendo $\sigma_{\hat{Y}Y}$ la covarianza de (\hat{Y}, Y) y $\sigma_{\hat{Y}}$ y σ_Y las desviaciones típicas de \hat{Y} e Y , respectivamente.

Finalmente, una vez realizada la validación cruzada se calculará la media aritmética de todas las iteraciones, obteniendo un error y un porcentaje de ajuste medio que representen el rendimiento del modelo.

2.3. COMPUTACIÓN EVOLUTIVA

Las técnicas de Computación Evolutiva están inspiradas en procesos naturales, sociales o de los animales para adaptarse al entorno, siguiendo los principios de la evolución natural definidos por Charles Darwin en “El Origen de las Especies por medio de la selección natural” [45]. Estas técnicas emulan dicho proceso para diseñar algoritmos consistentes en procedimientos iterativos que resuelven problemas complejos de búsqueda y aprendizaje explotando y explorando adecuadamente el espacio de búsqueda. Ejemplos de estos métodos son los Algoritmos evolutivos y algoritmos genéticos (GA), Optimización basada en Nube de Partículas (PSO), Optimización basada en Colonias de Hormigas y Optimización basada en Arrecifes de Coral (CRO) [38].

Este tipo de técnicas se emplean principalmente para resolver problemas de optimización. Parten de una población o conjunto de soluciones candidatas a resolver cierto problema, y estas soluciones interactúan entre sí a través de ciertos operadores, generando iterativamente nuevas soluciones al problema que serán posteriormente evaluadas por una función de adaptación diseñada según el problema a resolver. De esta forma sólo las mejores soluciones continúan en las siguientes generaciones, así hasta llegar a la mejor solución encontrada, por tanto combinan la

búsqueda aleatoria del proceso de transformación, con la búsqueda dirigida del proceso de selección.

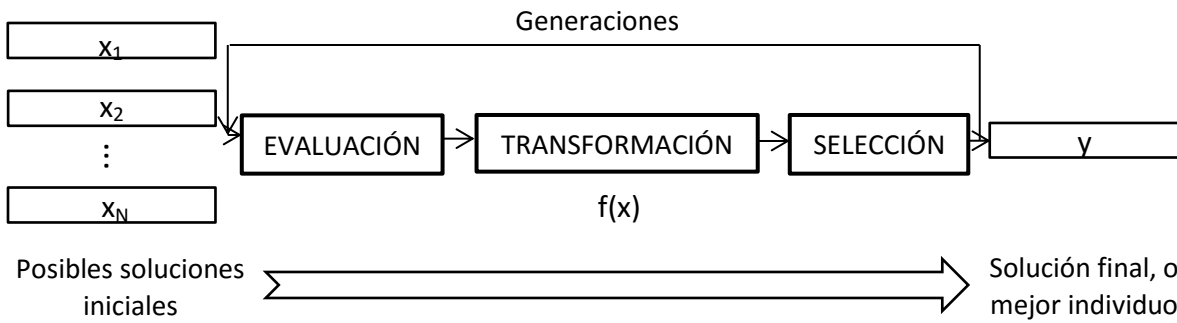


FIGURA 16. PROCEDIMIENTO DE LAS TÉCNICAS DE COMPUTACIÓN EVOLUTIVA.

2.3.1. ALGORITMOS GENÉTICOS

Los Algoritmos Genéticos son una clase de Algoritmos Evolutivos donde la población está constituida por cromosomas representados por una cadena de símbolos binarios. De forma resumida, ya que posteriormente en su implementación se entrará más en detalle, se puede decir que los algoritmos genéticos parten de una población inicial de individuos que representa un conjunto de posibles soluciones del espacio de búsqueda del problema. Estos individuos, también llamados cromosomas, tienen una longitud igual al número de variables o características involucradas en el proceso de optimización, y están formados por una cadena de símbolos binarios que representan un conjunto de esas variables.

A través de una función de fitness o adaptación, diseñada según el problema a optimizar, cada individuo tendrá un valor de fitness que indica cómo de válido es como solución para ese problema. Estos individuos evolucionarán a lo largo de varias generaciones mediante los operadores genéticos de cruce y mutación, que darán lugar a nuevos individuos a incorporar a la población con nuevos valores de fitness.

Por otro lado, el operador de selección determinará los individuos más aptos para continuar en la siguiente generación basándose en los valores de fitness de la nueva población obtenida tras el cruce y mutación, de esta manera se garantiza que sólo los mejores conjuntos de soluciones sobreviven y evolucionan adaptándose al problema y dando lugar a otras posibles soluciones.

El pseudocódigo que presenta un algoritmo genético simple equivale al presentado en el siguiente cuadro:

```
BEGIN /*Algoritmo genético*/
  Generar una población inicial.
  Calcular la función de fitness o adaptación de cada individuo.
  WHILE NOT Criterio de terminación DO
  BEGIN /*Nueva generación*/
    Cruce de individuos para generar nuevos individuos para la nueva generación.
    Mutación de individuos con cierta probabilidad.
    Seleccionar los mejores individuos que pasan a la siguiente generación.
    IF Ha convergido THEN
      Criterio de terminación=TRUE
    END IF
  END
END
```

FIGURA 17. PSEUDOCÓDIGO PARA ALGORITMO GENÉTICO SIMPLE. [46]

Lo que se trata de conseguir es que la aptitud media de la población para ese problema sea mejor en cada generación, y que tras miles de generaciones el algoritmo sea capaz de converger a un individuo final que será el óptimo del problema, o al menos de las soluciones encontradas.

Por tanto, se podría resumir que los Algoritmos Genéticos entienden el proceso evolutivo como una sucesión de cambios en los genes de los cromosomas que representan el conjunto de soluciones.

La manera en que se ha implementado este algoritmo en Matlab (generación de población inicial, bucle de cada nueva generación y funcionamiento del algoritmo), así como el diseño de la función de fitness adecuada para nuestro propósito, y la implementación de los operadores de cruce, mutación y selección, serán descritas posteriormente en la sección Implementación del Algoritmo Genético en Matlab.

Finalmente, hay que añadir que el éxito que tienen los Algoritmos Genéticos en la optimización de problemas complejos viene dado por sus principales características [47]:

- **Exploración en paralelo:** El espacio de búsqueda es explorado en varias direcciones gracias a la descendencia múltiple, pudiendo abandonar los caminos menos prometedores y dirigir la búsqueda hacia las direcciones con mejores resultados. Además, al evaluar a un individuo, realmente se están evaluando todos los espacios a los que pertenece la cadena de ese individuo, por tanto un AG explora de forma implícita un conjunto de individuos mucho mayor que el contenido en la población, obteniendo al cabo de varias generaciones la aptitud media de cada espacio y dirigiendo la evolución al espacio con mejor media para localizar el individuo más apto.

- Sin conocimiento previo: la población inicial es generada de forma aleatoria, no parte de ningún conocimiento previo y por tanto no se descarta ninguna solución a priori, basa sus decisiones en probabilidad y aleatoriedad.
- Funcionan bien en problemas no lineales: La no linealidad hace que exista una multitud de posibles combinaciones que explorar, ya que un cambio en un gen conllevará otros cambios en cadena, y un cambio, que individualmente puede ser perjudicial, en combinación con otros cambios puede mejorar la aptitud de la solución. Los AGs pueden hacer frente a este amplio abanico de posibilidades gracias a su paralelismo y encontrar buenas soluciones en periodos de tiempo relativamente cortos.
- Múltiples objetivos: Generalmente una solución implica una selección de parámetros que en conjunto son los que hacen que esa solución sea óptima. Al explorar en paralelo se puede llegar a distintas soluciones igualmente buenas, ya que puede suceder que una solución optimice un objetivo y otra uno distinto.
- Habilidad para escapar de óptimos locales y descubrir el óptimo global: Aunque no se conozca con seguridad si se trata de óptimo global o un óptimo local muy bueno, un AG es capaz de llegar a una muy buena solución.

No obstante, también presentan algunas limitaciones, entre ellas destacan la importancia del diseño adecuado de la función de fitness para encontrar una solución que realmente sea mejor para el problema dado, y también la dependencia de parámetros como el tamaño de la población y el número de generaciones para explorar un conjunto de soluciones suficientemente grande pero sin penalizar en exceso el tiempo de ejecución del algoritmo. Se debe conseguir un ritmo de convergencia adecuado, aunque podría suceder que el algoritmo no convergiera o que convergiera prematuramente a un óptimo local. Esta última es la limitación más importante, ya que si apareciese muy pronto un individuo o solución que superase considerablemente en aptitud al resto de los individuos éste se va a reproducir y va a reducir la búsqueda a ese espacio, llevando posiblemente al algoritmo a converger sin haber explorado suficientes posibles soluciones.

2.3.2. PROBLEMA DE SELECCIÓN DE CARACTERÍSTICAS

El Problema de Selección de Características, conocido en Inteligencia Artificial como “Feature Selection Problem” (FSP, [48]) surge cuando el conjunto de variables de entrada empleado para entrenar un modelo contiene numerosas características, haciendo que el coste de disponer de ese conjunto de datos sea mayor, aumentando también el tiempo de ejecución y perjudicando al rendimiento del entrenamiento del modelo. Por este motivo se hace necesario detectar si existen características de entrada al modelo que no sean relevantes para el problema a resolver.

En este Trabajo Fin de Máster se va a entrenar en cierto momento un modelo neuronal en el que se han incorporado variables meteorológicas para evaluar su comportamiento en la predicción de

extremos de viento. Para optimizar el error de predicción obtenido con este modelo se lleva a cabo un proceso de búsqueda del mejor subconjunto de características. El enfoque empleado es conocido como “wrapper method” para selección de características, descrito en la Figura 18. Este método consiste en seleccionar un subconjunto de características del total que consiga el error de predicción más bajo, igual o menor al error que se tiene con el conjunto total inicial.

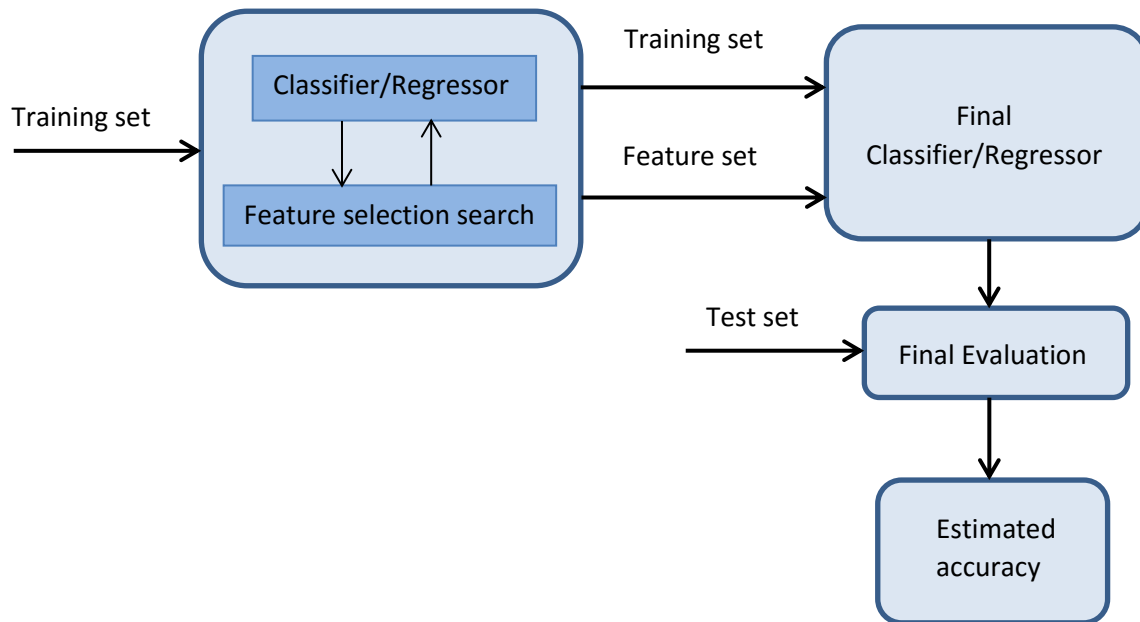


FIGURA 18. DIAGRAMA DEL MÉTODO “WRAPPER” PARA SELECCIÓN DE CARACTERÍSTICAS. [36]

En este caso el modelo de regresión que se empleará será una red neuronal que será entrenada mediante el algoritmo ELM, y para llevar a cabo el algoritmo de búsqueda de características se empleará un algoritmo genético.

El motivo por el que se han empleado algoritmos genéticos para selección de características es porque el impacto de las variables en el modelo no se estudia de forma individual sino que son las combinaciones de las variables las que se evalúan. Existen técnicas que basan la selección de características en evaluar cómo afecta al rendimiento del modelo añadir o retirar una variable de entre el conjunto de características de entrada, pero de esta forma no se tiene en cuenta la relación que puede existir entre variables, ya que puede suceder que la información que ofrece una variable al modelo sólo sea relevante si se encuentra en combinación con otra. Además, esta técnica generalmente presenta problemas de “overfitting”, ya que la selección se lleva a cabo en función del impacto que han tenido las variables en las muestras del conjunto de entrenamiento, que será distinto al impacto que se tenga en el conjunto de validación. Este problema no se da al emplear algoritmos genéticos ya que incorporan operadores de cruce y mutación que permiten generalizar el problema al evaluar una gran variedad de combinaciones posibles, aunque la carga computacional es mayor.

IMPLEMENTACIÓN DEL ALGORITMO GENÉTICO EN MATLAB

Como ya se comentaba anteriormente este tipo de algoritmos son empleados principalmente para resolver problemas de optimización, cuyo objetivo es hallar un conjunto de variables que, combinadas, cumplan cierto criterio de calidad impuesto por una función de evaluación.

Previamente se exponía el motivo de emplear algoritmos genéticos para realizar la búsqueda de características, principalmente porque cuantos más atributos se tengan más largo y complejo será el proceso de predicción y más costoso disponer de dichos atributos. Por este motivo es necesario realizar una selección de características, porque puede suceder que de las múltiples variables disponibles algunas resulten irrelevantes o perjudiciales, igual que otras pueden ser imprescindibles para poder obtener buenos resultados. Además, entrenar la red con el subconjunto de características esenciales iguala, o incluso mejora, la precisión del modelo obtenida con el conjunto de características completo.

En este Trabajo Fin de Máster se ha empleado un Algoritmo Genético para seleccionar las características de entrada a la red neuronal, implementada con el algoritmo ELM, que resulten más relevantes para este problema de predicción.

El algoritmo comienza con la generación de una población inicial de individuos, que son cromosomas que codifican en binario la combinación de características de entrada que representan ('1' equivale a característica seleccionada y '0' no seleccionada). Esta población inicial es, además, evaluada con la función de adaptación o función fitness diseñada para este problema de predicción. En este caso se tiene una población de 100 individuos y se ha diseñado la función fitness para ejecutar el algoritmo ELM con cada combinación de atributos representada por el individuo, determinando el nivel de adaptación de ese individuo a través del cálculo del error medio de las iteraciones que componen la validación cruzada en la fase de validación de la red con esa combinación de características. Ese error medio será el error de predicción asociado a ese individuo.

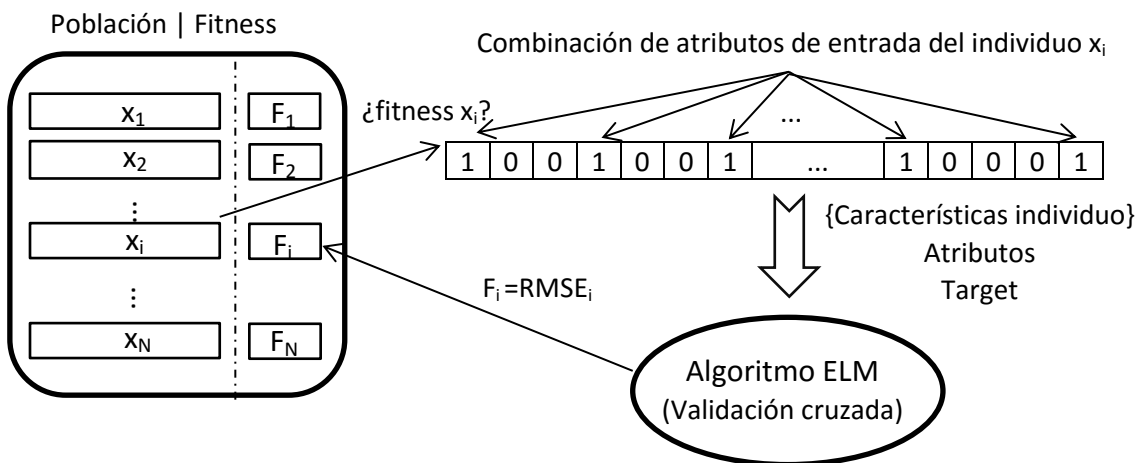


FIGURA 19. DIAGRAMA DE DISEÑO DE LA FUNCIÓN DE FITNESS.

Después de la evaluación de la población inicial y el cálculo del fitness que presenta cada cromosoma que la constituye, comienza la fase reproductiva. En ella tiene lugar la selección de

dos individuos, llamados padres, que serán cruzados para dar lugar a dos nuevos individuos, llamados hijos, que podrán mutar con cierta probabilidad de mutación antes de ser evaluados por la función de fitness y de incorporarse a la población total. Finalmente, tiene lugar un torneo entre los individuos que forman la población total de esa generación, de forma que los dos individuos con peor fitness (lo que implica mayor error) son eliminados del conjunto de posibles soluciones, manteniéndose así el tamaño de la población en cada generación.

Este proceso se repite a lo largo de varias generaciones simulando el proceso de evolución o de adaptación de individuos al entorno hasta alcanzar un criterio de terminación. Este criterio que marca la finalización del algoritmo evolutivo depende del diseño del algoritmo, podría venir dado por un número máximo de generaciones alcanzadas o por la permanencia de una misma solución como solución más apta durante un elevado número de generaciones consecutivas. En este caso se ha optado por fijar cierto número de generaciones máximo para cada ejecución del algoritmo genético, que ha sido escogido por encima del número de generaciones a partir del cual el algoritmo ha convergido en las dos primeras simulaciones para un mismo problema de selección.

El diagrama de bloques de la Figura 20 muestra el proceso seguido por el algoritmo genético. Puede verse que el proceso evolutivo que presenta un algoritmo genético consta de un operador evolutivo: Selección; y unos operadores genéticos: Cruce y mutación.

Por un lado, los operadores de cruce y mutación se aplican a los dos padres seleccionados y a su descendencia, respectivamente, con la intención de generar dos individuos distintos que tal vez puedan tener un valor de fitness mejor. El funcionamiento de estos operadores es el siguiente:

- **Operador de cruce:** Es el operador con el cual se genera la descendencia mediante una combinación de los genes de los padres. En este caso se ha optado por un operador de cruce basado en dos puntos, que consiste en seleccionar dos puntos de corte aleatorios de los padres e intercambiar los fragmentos de código que quedan fruto de esos cortes. Se ha elegido un cruce en dos puntos para poder explorar el espacio de búsqueda más fácilmente, sin provocar la ruptura de buenos esquemas.
- **Operador de mutación:** Con este operador se trata de evitar caer en óptimos locales a costa de añadir cierto ruido o aleatoriedad a la población, por ello este cambio sucede con baja probabilidad. Consiste en cambiar el valor binario de cierto porcentaje aleatorio de genes de un individuo con cierta probabilidad. Para este estudio se ha escogido una probabilidad de mutación del 5% y un porcentaje de genes a mutar del 30%.

Por otro lado, el operador de selección será el encargado de escoger los mejores individuos que pasarán a la siguiente generación y eliminar los peores. En este caso se ha optado por realizar selección por torneo. Esta selección consiste en que cada individuo de la población se debe enfrentar a cierto porcentaje de contrincantes para comparar su valor de fitness, de forma que un individuo sumará una victoria cuando tenga un valor de fitness mayor al de su contrincante. Así, una vez se conoce el número de victorias de cada individuo, se eliminarán los dos individuos con mayores victorias, ya que en este caso se ha diseñado que el valor de fitness venga dado por el valor del error de predicción. Para este estudio se ha escogido que cada individuo se enfrente con el 90% de la población.

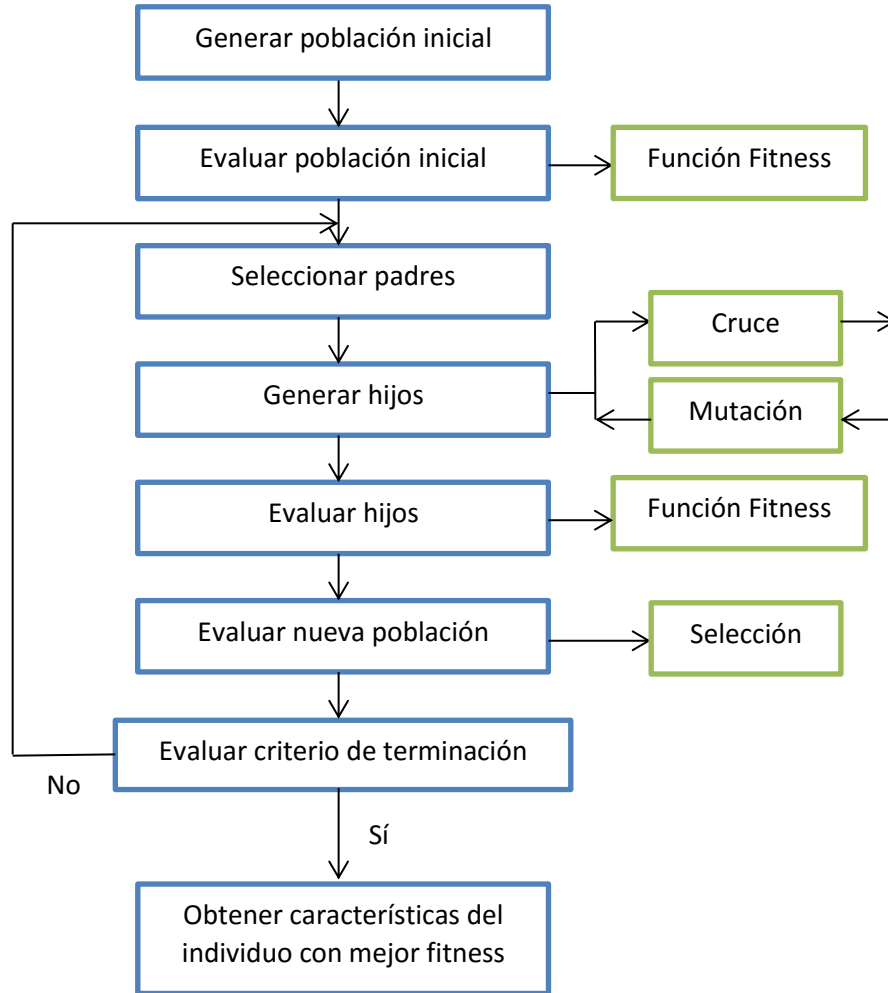


FIGURA 20. DIAGRAMA DE BLOQUES DEL ALGORITMO GENÉTICO IMPLEMENTADO.

Es importante tener en cuenta que, previo a la ejecución del GA, el conjunto de datos disponible formado por el target y los atributos de velocidad de viento y de reanálisis será dividido en conjunto de Train y conjunto de Test, ya que la selección de características debe hacerse considerando únicamente el conjunto de Train.

Posteriormente, al ejecutar la función de fitness del GA que entrena y prueba la red con la combinación de variables de entrada definida por cada individuo, se ha optado por emplear validación cruzada que generalice los resultados obtenidos, por lo que este conjunto de Train será dividido a su vez en conjuntos de Train y Test con cada iteración de las que componen este proceso, siendo el valor de fitness del individuo el error medio de validación de estas iteraciones.

Finalmente, una vez encontrado el mejor individuo, se calculará su error de predicción asociado empleando para la ELM final los conjuntos de Train y Test originales (sin el empleo de validación cruzada) con las características que componen a este individuo.

Por otro lado, en cuanto a la implementación de este algoritmo genético en Matlab, se tiene un script principal que es donde se sigue el proceso evolutivo (compuesto por las etapas que indican

los recuadros en azul de la Figura 20), y desde él se llama a la función de fitness y a las funciones que implementan los operadores de cruce, mutación y selección (recuadros en verde) cuando corresponda.

A continuación se muestran los prototipos y argumentos de entrada y salida de dichas funciones:

Prototipo: [error] = fitness (poblacion, caract, target)	
Argumentos de entrada	
Poblacion	Población inicial generada compuesta por cierto número de individuos o cromosomas de 1's y 0's con longitud igual al número de variables de entrada a analizar, en este caso 54 (datos de velocidades y reanálisis).
Caract	Matriz de atributos de entrada, formada por Atributos de velocidad y predictores de reanálisis.
Target	Vector de target o salida deseada.
Argumentos de salida	
Error	Vector que contiene el error de validación de la red para cada una de las combinaciones de características indicadas por los cromosomas, retornado por el algoritmo ELM.
Prototipo: [hijo1,hijo2] = cruce (padre1, padre2)	
Argumentos de entrada	
Padre1, padre2	Individuos seleccionados para realizar el cruce.
Argumentos de salida	
Hijo1, hijo2	Individuos generados tras el cruce de padre1 y padre2.
Prototipo: [hijo1,hijo2] = mutacion (hijo1, hijo2)	
Argumentos de entrada	
Hijo1, hijo2	Individuos que han sido generados en el cruce y son candidatos para realizar la mutación, con una probabilidad de mutación del 5% y un 30% de genes a mutar si se da el caso.
Argumentos de salida	
Hijo1, hijo2	Resultado de los individuos tras la mutación de genes, pudiendo haber mutado o no.
Prototipo: [victorias] = torneo (fitness_total, poblacion_total)	
Argumentos de entrada	
Fitness_total	Vector que contiene el valor de fitness o adaptación al problema de cada individuo de la población.
Poblacion_total	Población de individuos en esa generación.
Argumentos de salida	
Victorias	Vector que contiene el número de veces que el fitness de un individuo supera al de otro individuo. Los 2 individuos con mayor número de victorias (peor fitness) serán eliminados en cada generación.

TABLA 2. ARGUMENTOS DE ENTRADA Y SALIDA DE LA FUNCIÓN DE FITNESS Y DE LOS OPERADORES DE CRUCE, MUTACIÓN Y SELECCIÓN.

3. MATERIAL

3.1. DATOS DE VELOCIDAD DE VIENTO

Para el objetivo perseguido en este Trabajo Fin de Máster se han proporcionado los datos de velocidad de viento, en m/s, medidos en el parque eólico de Peñaparda, un municipio español situado en la provincia de Salamanca cuyas coordenadas en grados decimales son:

- Latitud: 40.2665477
- Longitud: -6.6262572

Estos datos de viento se presentan de forma horaria en el periodo comprendido entre el 23 de noviembre de 1995 y el 17 de febrero de 2013, suponiendo un total de 6.297 días, equivalente a 151.128 horas.

La matriz que recoge los datos de velocidad de viento de Peñaparda para el periodo de estudio tiene, por tanto, un tamaño de 151.128 filas, correspondientes a los datos de velocidad de viento cada hora, y 5 columnas, que se identifican con los siguientes campos de la Tabla 3:

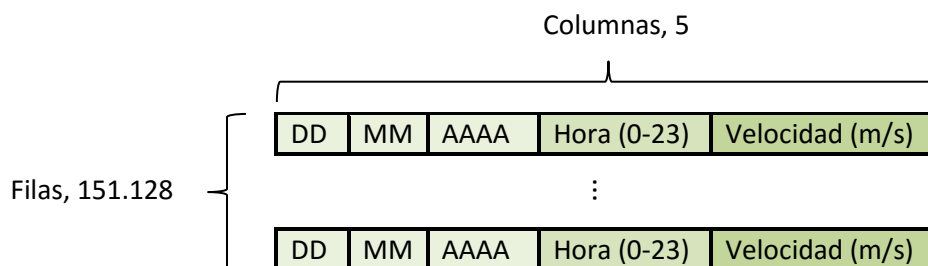


TABLA 3. MATRIZ DE DATOS DE VELOCIDAD DE VIENTO EN PEÑAPARDA.

Esta matriz será empleada, por un lado, para formar el conjunto de características o variables de entrada a introducir al algoritmo ELM, tras una previa ordenación de los datos de velocidad de viento que será vista posteriormente y, por otro lado, para obtener el vector de salida o de target que contiene el dato de velocidad máxima en las 6h siguientes. Será necesario disponer de ella desde el primer experimento inicial ya que constituye el dataset de partida sobre el que se incorporarán las características de reanálisis en los experimentos posteriores.

Como paso previo a constituir la matriz de datos de entrada a la ELM se deben analizar los datos de los que se dispone. Un hecho importante es que esta matriz de partida con los datos de velocidad de viento horarios de Peñaparda contiene datos de velocidad con valor igual a -99 m/s. El motivo de estos datos no válidos es poder disponer de un registro para cada hora en la matriz completa, de esta forma cuando el anemómetro no ha sido capaz de captar una medida de velocidad válida se ha identificado esa hora en el conjunto de datos asignándole dicho valor, -99 m/s. En total son 15.105 horas las afectadas por esta pérdida de dato de velocidad. Además, se ha

podido detectar en la matriz que existen datos de velocidad consecutivos, próximos a esos huecos de medida, cuyo valor de velocidad es inferior a 0.1 m/s, y se ha optado por identificarlos como no válidos asignándoles también valor -99 m/s ya que por su situación y valor no van a considerarse medidas válidas. En total suman 15.185 datos de velocidad no válidos, en torno al 10% del total.

Tras el análisis de los datos proporcionados garantizando que existe un dato para cada hora comprendida en esos 6.297 días, ya sea dato válido o no, y la identificación como no válida de las velocidades inferiores a 0.1m/s próximas a los huecos, está preparada la matriz de datos de partida. La evolución de los datos de velocidad, junto con los huecos de velocidad de valor -99m/s, puede verse en la Figura 21.

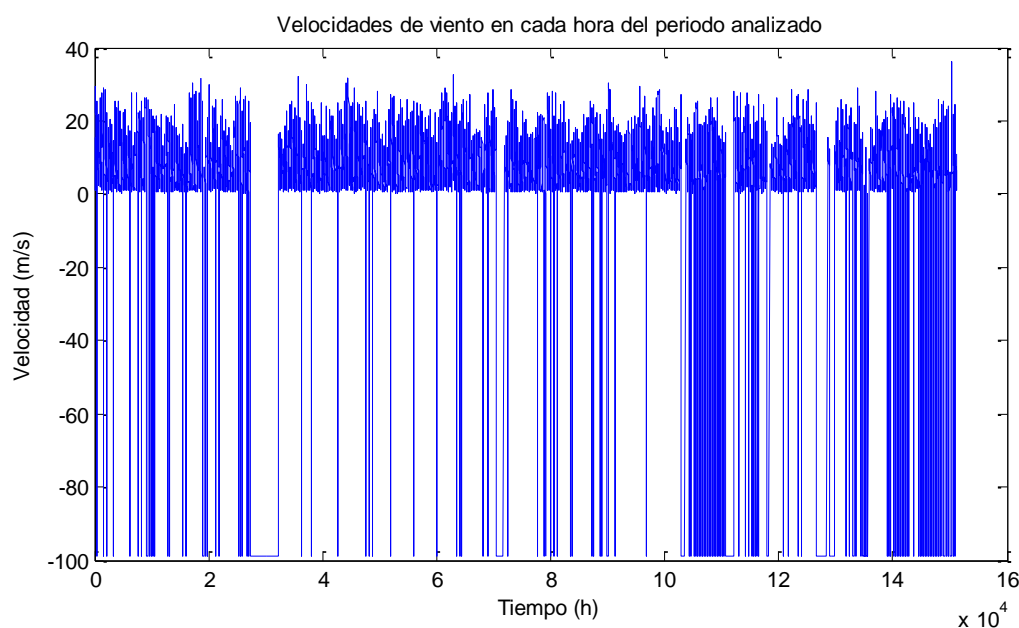


FIGURA 21. DATOS DE VELOCIDAD DE VIENTO HORARIOS DE LA MATRIZ DE PARTIDA.

3.2. DATOS DE REANÁLISIS

Además de la matriz de velocidades de viento ya comentada, será necesario disponer de los datos de reanálisis que se desean incorporar al modelo como continuación del experimento inicial en el que solo intervienen variables de velocidad de viento. Estos datos de reanálisis se han obtenido de cuatro estaciones de medida próximas al parque eólico de Peñaparda, aunque se entrará más en detalle en su objetivo en la parte experimental.

Para ello se ha proporcionado una matriz de predictores de reanálisis para este parque eólico. Dichos datos han sido extraídos del ERA-Interim [49], un tipo de dataset de reanálisis recogido por el ECMWF (European Centre for Medium-Range Weather Forecasts) basado en históricos de mediciones sobre la atmósfera, la superficie de la Tierra y los océanos.

Para el caso que ocupa este Trabajo Fin de Máster, se ha proporcionado el histórico en el periodo de análisis (23 de Noviembre de 1995 a 17 de Febrero de 2013) para 12 variables meteorológicas relacionadas con el viento procedentes de esas 4 estaciones de medida situadas en diferente localización. Las variables de reanálisis obtenidas aparecen enumeradas en la Tabla 4.

Nombre de la variable	Variable ERA-Interim
skt	Temperatura de la superficie
sp	Presión de la superficie
u ₁₀	Componente zonal de viento (u) a 10m
v ₁₀	Componente meridional de viento (v) a 10m
temp1	Temperatura a 500hPa
up1	Componente zonal de viento (u) a 500hPa
vp1	Componente meridional de viento (v) a 500hPa
wp1	Componente vertical de viento (w) a 500hPa
temp2	Temperatura a 850hPa
up2	Componente zonal de viento (u) a 850hPa
vp2	Componente meridional de viento (v) a 850hPa
wp2	Componente vertical de viento (w) a 850hPa

TABLA 4. CARACTERÍSTICAS DE REANÁLISIS OBTENIDAS DEL ERA-INTERIM.

La matriz de reanálisis proporcionada tiene un tamaño de 25.187 filas, correspondiente a los datos de reanálisis cada 6 horas durante 6.297 días (mismo periodo de análisis que la matriz de datos, salvo que empieza con los predictores de la hora 6 en vez de en la hora 0), y 48 columnas, que se identifican con las características de reanálisis de las 4 estaciones, 12 por cada estación.




TABLA 5. MATRIZ DE DATOS DE REANÁLISIS EN PEÑAPARDA.

Dado que las variables de reanálisis se tienen con un periodo de 6 horas, para poder realizar una segunda aproximación sobre el primer experimento incluyendo estas variables es necesario adaptar los datos de velocidad de viento de Peñaparda a un periodo de muestreo de 6 horas. Por este motivo los datos horarios de viento empleados tanto en el primer experimento como en posteriores mejoras, se agruparán en ventanas de 6 horas que se emplearán como características de entrada a la ELM.

4. RESULTADOS

4.1. INTRODUCCIÓN

Llegados a este punto, se ha justificado por qué es necesario optimizar la predicción de velocidades de viento en los parques eólicos, qué ventajas y limitaciones presenta, y cuáles son las técnicas de aprendizaje automático que se van a emplear en este Trabajo Fin de Máster para realizar el estudio de predicción.

En el apartado anterior se expusieron los datos de partida, tanto de velocidad de viento como de reanálisis, detallando también las particularidades que presentan, como es el caso de presentar huecos de medida o valores de velocidad demasiado bajos que se han considerado datos no válidos, y el periodo en que se han recogido ambos tipos de datasets, surgiendo la necesidad de reorganizar los datos de velocidad de viento para transformarlos de un periodo horario a un periodo de 6 horas, haciéndolo coincidir con el periodo de muestreo de los datos de reanálisis.

En este apartado se van a exponer los distintos experimentos realizados. En primer lugar se tendrá un experimento base, que realizará la predicción del máximo de velocidad de viento en las 6 horas siguientes conociendo el valor de velocidad de las 6 horas anteriores a través del entrenamiento de una red neuronal mediante el algoritmo ELM. En segundo lugar, se realizará una modificación del experimento base, consistente en incorporar a las variables de velocidad de viento de las 6 horas anteriores las variables de reanálisis correspondientes provenientes de las cuatro estaciones de medida. Y en tercer lugar, como paso previo a la predicción se seleccionará el subconjunto de características tanto de velocidades de viento como de reanálisis que resultan más relevantes para obtener la salida de predicción haciendo uso del algoritmo genético.

Los siguientes diagramas de bloques muestran de forma gráfica el propósito de cada experimento, comenzando por el experimento base de predicción y continuando con las posteriores mejores implementadas con el objetivo de optimizar los resultados.

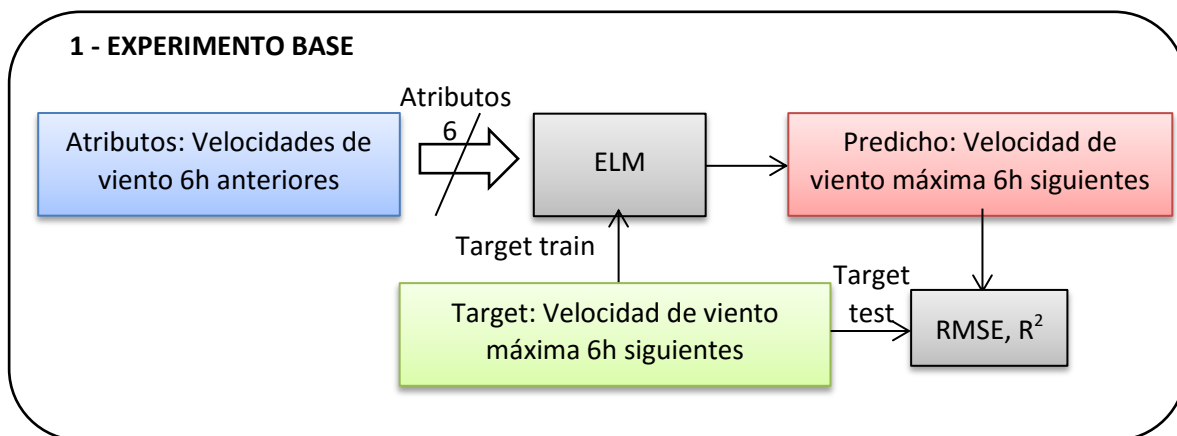


FIGURA 22. DIAGRAMA EXPERIMENTO BASE.

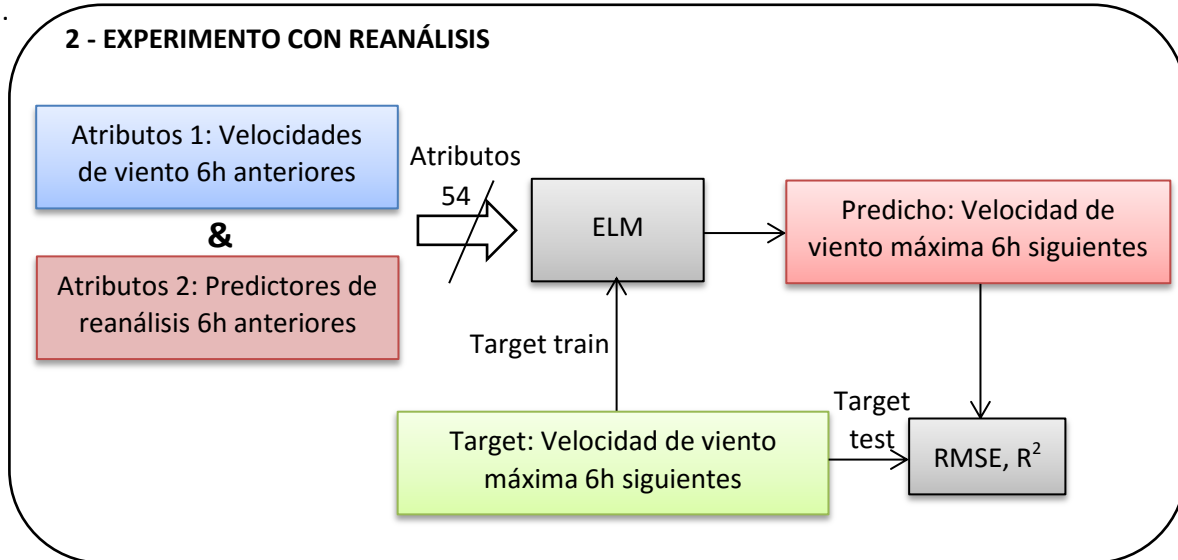


FIGURA 23. DIAGRAMA EXPERIMENTO CON REANÁLISIS.

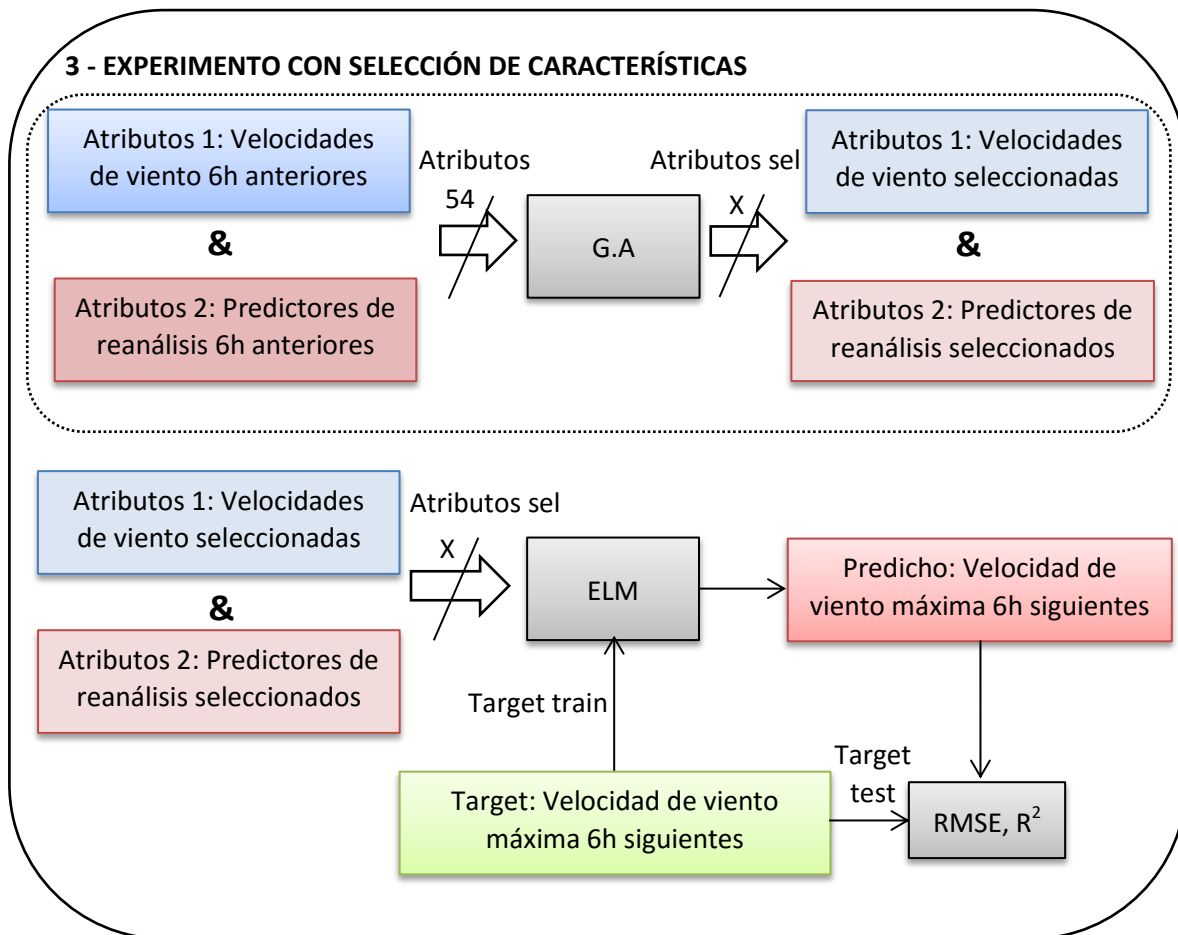


FIGURA 24. DIAGRAMA EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS.

4.2. PREPARACIÓN INICIAL DE LOS DATOS

Como ya se indicaba en la introducción, las variables de velocidad de viento recogidas en la matriz de datos proporcionada van a ser procesadas antes de emplearlas para entrenar y testear la red. Este procesamiento consiste en dos etapas, una primera etapa donde se escoge cómo diseñar el conjunto de datos para entrenar y testear la red, si empleando ventana fija o empleando ventana móvil, y una segunda etapa que corresponde a la eliminación de ejemplos de ese conjunto de datos que no sean válidos.

El motivo de emplear ventana en el conjunto de datos para formar la matriz que contiene las variables de entrada a la red se debe a que las medidas de reanálisis han sido tomadas en periodos de 6 horas, mientras que los datos de velocidad de viento son horarios. En el apartado anterior ya se comentó esta diferencia, indicando que para poder realizar simulaciones con ambos conjuntos era necesario adaptar los periodos de muestreo. En un primer lugar se optó por emplear ventana fija de tamaño 6, quedando 6 variables de velocidad de viento por cada fila de la matriz de datos que serían las variables de entrada al algoritmo ELM, y donde se concatenaría en horizontal la matriz de reanálisis. Dado que el conjunto de ejemplos disponibles para el entrenamiento y test se ve reducido con esta opción, posteriormente se pensó en emplear ventana móvil de tamaño 6 desplazada una posición en cada fila y asignar a cada fila las medidas de reanálisis más cercanas a ese rango horario, teniendo que replicar los mismos predictores hasta para 6 filas consecutivas. De esta forma se dispone de un mayor número de ejemplos para entrenar y testear la red.

La siguiente Figura 25 muestra cómo se haría el procesado de la matriz de datos proporcionados para obtener el dataset para el Experimento inicial en función del tipo de ventana:

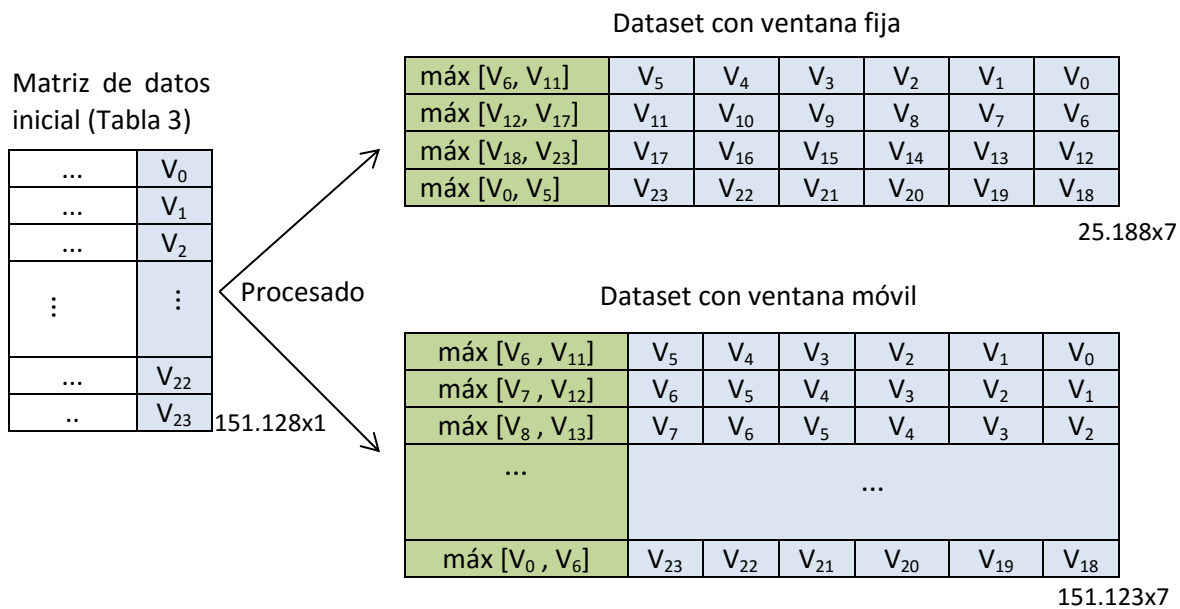


FIGURA 25. FRAGMENTO DE DATASET EN EL EXPERIMENTO BASE.

En el caso del Experimento con reanálisis estas matrices incorporarán al dataset de velocidades de viento los predictores de reanálisis. Para el caso de ventana fija, la asociación entre atributos de

velocidad y atributos de reanálisis es directa, puesto que ambos tienen ahora el mismo periodo de 6h entre ejemplos. Sin embargo, para el caso de ventana móvil, donde el desplazamiento de la ventana entre ejemplos es únicamente de una hora, se ha optado por asignar a cada ventana de velocidades de viento los predictores de reanálisis más cercanos a ese intervalo, como indica en la Tabla 6, de forma que van a existir ventanas de datos de viento que comparten los mismos datos de reanálisis.

Intervalo de medidas con ventana móvil de tamaño 6.	Predictores de reanálisis.
{1h-6h}	Predictores en la hora 6
{2h-7h}	
{3h-8h}	
{4h-9h}	
{5h-10h}	
{6h-11h}	
{7h-12h}	Predictores en la hora 12
{8h-13h}	
{9h-14h}	
{10h-15h}	
{11h-16h}	
{12h-17h}	
{13h-18h}	Predictores en la hora 18
{14h-19h}	
{15h-20h}	
{16h-21h}	
{17h-22h}	
{18h-23h}	
{19h-0h}	Predictores en la hora 0
{20h-1h}	
{21h-2h}	
{22h-3h}	
{23h-4h}	
{0h-5h}	

TABLA 6. ASIGNACIÓN DE PREDICTORES DE REANÁLISIS CON VENTANA MÓVIL.

La forma que toman las matrices de datos para el Experimento con reanálisis se muestra en la Figura 26:

Dataset con ventana fija

Target	Atributos						Reanálisis
máx [V ₆ , V ₁₁]	V ₅	V ₄	V ₃	V ₂	V ₁	V ₀	Predictores h. 0
máx [V ₁₂ , V ₁₇]	V ₁₁	V ₁₀	V ₉	V ₈	V ₇	V ₆	Predictores h. 6
máx [V ₁₈ , V ₂₃]	V ₁₇	V ₁₆	V ₁₅	V ₁₄	V ₁₃	V ₁₂	Predictores h. 12
máx [V ₀ , V ₅]	V ₂₃	V ₂₂	V ₂₁	V ₂₀	V ₁₉	V ₁₈	Predictores h. 18
...	V ₅	V ₄	V ₃	V ₂	V ₁	V ₀	Predictores h. 0

25187x7

Dataset con ventana móvil

Target	Atributos						Reanálisis
máx [V ₆ , V ₁₁]	V ₅	V ₄	V ₃	V ₂	V ₁	V ₀	Predictores h. 0
máx [V ₇ , V ₁₂]	V ₆	V ₅	V ₄	V ₃	V ₂	V ₁	Predictores h. 6
máx [V ₈ , V ₁₃]	V ₇	V ₆	V ₅	V ₄	V ₃	V ₂	Predictores h. 6
...
máx [V ₂₃ , V ₅]	V ₂₂	V ₂₁	V ₂₀	V ₁₉	V ₁₈	V ₁₇	Predictores h. 18
máx [V ₀ , V ₆]	V ₂₃	V ₂₂	V ₂₁	V ₂₀	V ₁₉	V ₁₈	Predictores h. 18
máx [V ₁ , V ₇]	V ₀	V ₂₃	V ₂₂	V ₂₁	V ₂₀	V ₁₉	Predictores h. 0

151.122x6

FIGURA 26. FRAGMENTO DE DATASET EN EL EXPERIMENTO CON REANÁLISIS.

Finalmente, en el experimento con evolutivo el dataset de partida es el mismo que en el experimento con reanálisis, ya que el objetivo es que el algoritmo evolutivo lo emplee para entrenar a la red con distintas combinaciones de las características de entrada hasta encontrar la combinación que mejores resultados ha dado.

Ahora que se conoce la estructura final que tendrán las matrices de Target y Características que componen el conjunto de datos de entrada de la red, se debe continuar con la segunda etapa de preparación de los datos, que consiste en limpiar dichos datasets de datos no válidos.

Como ya se comentó en el apartado anterior, existen huecos de medida de velocidad de viento con valor de -99m/s, y datos de velocidad identificados como no válidos por su posición y valor. Estos datos no podrán emplearse como variables de entrada a la red neuronal ya que alterarían la predicción, por tanto es necesario eliminarlos.

Para el caso de ventana fija, analizando la cantidad de datos no válidos que contienen las filas de la matriz de Atributos de velocidad se llega a la siguiente conclusión de la Tabla 7:

Total filas Atributos: 25.188	Filas con todos los datos válidos: 22.369	
	Filas con algún dato no válido: 2.819	Filas con 5 datos válidos: 195
		Filas con 4 datos válidos: 107
		Filas con 3 o menos datos válidos: 2.517

TABLA 7. ANÁLISIS DE DATOS NO VÁLIDOS EN LA MATRIZ DE ATRIBUTOS PARA VENTANA FIJA.

Dado que el conjunto de filas que tienen 4 o 5 datos válidos no son suficientes para entrenar una red neuronal individual para cada uno de los casos y así obtener unos resultados de predicción basados en la media de las distintas redes neuronales, se ha optado por considerar fila de atributos no válida a aquella fila que tenga algún dato no válido. Esto conlleva eliminar las filas de atributos (o ejemplos) que no tengan todos sus datos válidos, y también las filas que contengan una velocidad máxima no válida (fruto de un dato no válido en las 6 horas siguientes).

Independientemente de que el conjunto de datos esté compuesto por atributos de velocidad, como en el experimento base, o atributos de velocidad y predictores de reanálisis, como el experimento con reanálisis, el procedimiento a seguir es el mismo y depende de los datos no válidos de velocidad. La Figura 27 muestra un ejemplo de esta situación, marcando con una cruz los datos no válidos y tachando las filas que se deberían eliminar:

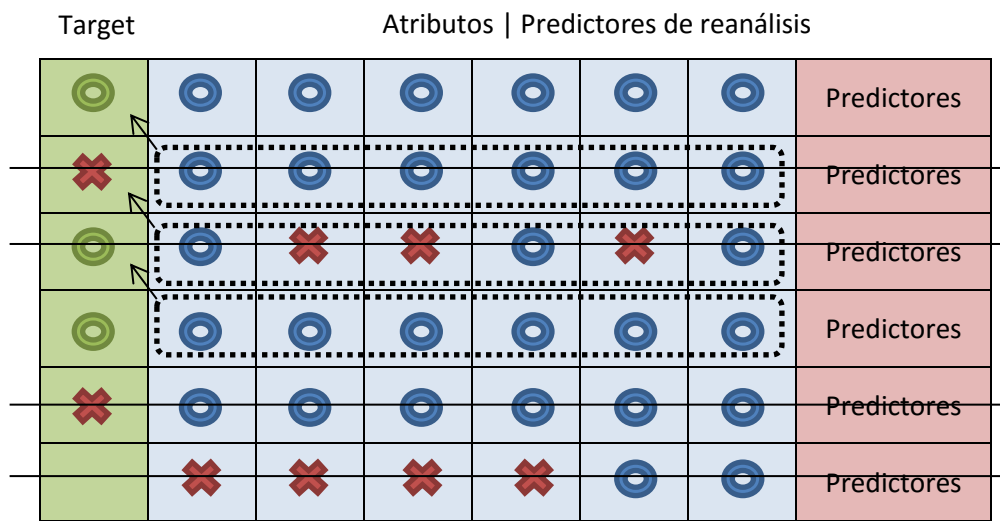


FIGURA 27. EJEMPLO DE LIMPIEZA DE DATOS NO VÁLIDOS DEL DATASET.

Ante esta situación, una vez formado el dataset se procederá a eliminar, por un lado, las filas que tengan algún dato no válido en sus atributos de velocidad (2.819 filas), y por otro, las filas que tengan un target no válido (290 filas), además de la última fila que no dispone de target, resultando en un tamaño de matrices válidas para ventana fija de 22.078 filas.

Es importante que esta limpieza se haga una vez formado el conjunto de datos, ya que si se eliminasen primero las filas de atributos no válidos y después se formase el vector de target con el máximo en las 6 horas siguientes se podría caer en el error de querer predecir el máximo que se tendrá pasados varios días o meses, según la cantidad de datos no válidos que hubiera intercalados.

De igual forma, en el caso de ventana móvil, la Tabla 8 muestra el análisis de las filas con datos no válidos en la matriz de de Atributos de velocidad. Se sigue el mismo proceso de limpieza de los datos que con ventana fija, considerando fila de atributos no válida a aquella fila que tenga algún dato no válido. El tamaño final de las matrices válidas para ventana móvil es de 132.499 filas.

Total filas Atributos: 151.223	Filas con todos los datos válidos: 134.251	
	Filas con algún dato no válido: 16.872	Filas con 5 datos válidos: 1.220
		Filas con 4 datos válidos: 552
		Filas con 3 o menos datos válidos: 15.100

TABLA 8. ANÁLISIS DE DATOS NO VÁLIDOS EN LA MATRIZ DE ATRIBUTOS PARA VENTANA MÓVIL.

4.3. EXPERIMENTO BASE

OBJETIVO: A partir del dataset compuesto por 6 datos horarios consecutivos de velocidad de viento y por un target, que es la velocidad máxima en las 6 horas siguientes, obtener la salida de predicción de la red neuronal artificial entrenada y testeada mediante el algoritmo ELM.

CONDICIONES:

1. Las variables de entrada se componen únicamente de los 6 datos de velocidad de viento.
2. Se utilizará validación cruzada aleatoria para entrenar y testear la red, con 10 iteraciones y proporción Train-Test 80-20%.

REQUISITOS INICIALES:

- Se deben cuadrar ambas matrices de atributos de velocidad y target. Será necesario eliminar la última ventana de atributos, ya que no dispone de 6 horas siguientes donde obtener el máximo.
- Una vez formado el conjunto [Target, Atributos] será necesario eliminar aquellas ventanas no válidas, tal como se describió anteriormente.

MATRICES DE PARTIDA:

Ventana fija	Ventana móvil
Atributos [22078,6]; Target [22078,1];	Atributos [132499,6]; Target [132499,1];

TABLA 9. MATRICES VÁLIDAS PARA EL EXPERIMENTO BASE.

EVALUACIÓN DEL NÚMERO DE NEURONAS DE LA CAPA OCULTA: Uno de los parámetros necesarios a configurar en la red neuronal, tal y como se veía durante la base teórica del algoritmo ELM, es el número de neuronas que tendrá la capa oculta de la red. Por este motivo resulta interesante conocer cómo se va a comportar la red, en términos de calidad de la predicción basada en RMSE y R^2 , para cada valor de neuronas ocultas propuesto.

A continuación se muestran los resultados obtenidos tanto para los mejores valores de RMSE y R^2 como para sus valores medios.

➤ Ventana fija.

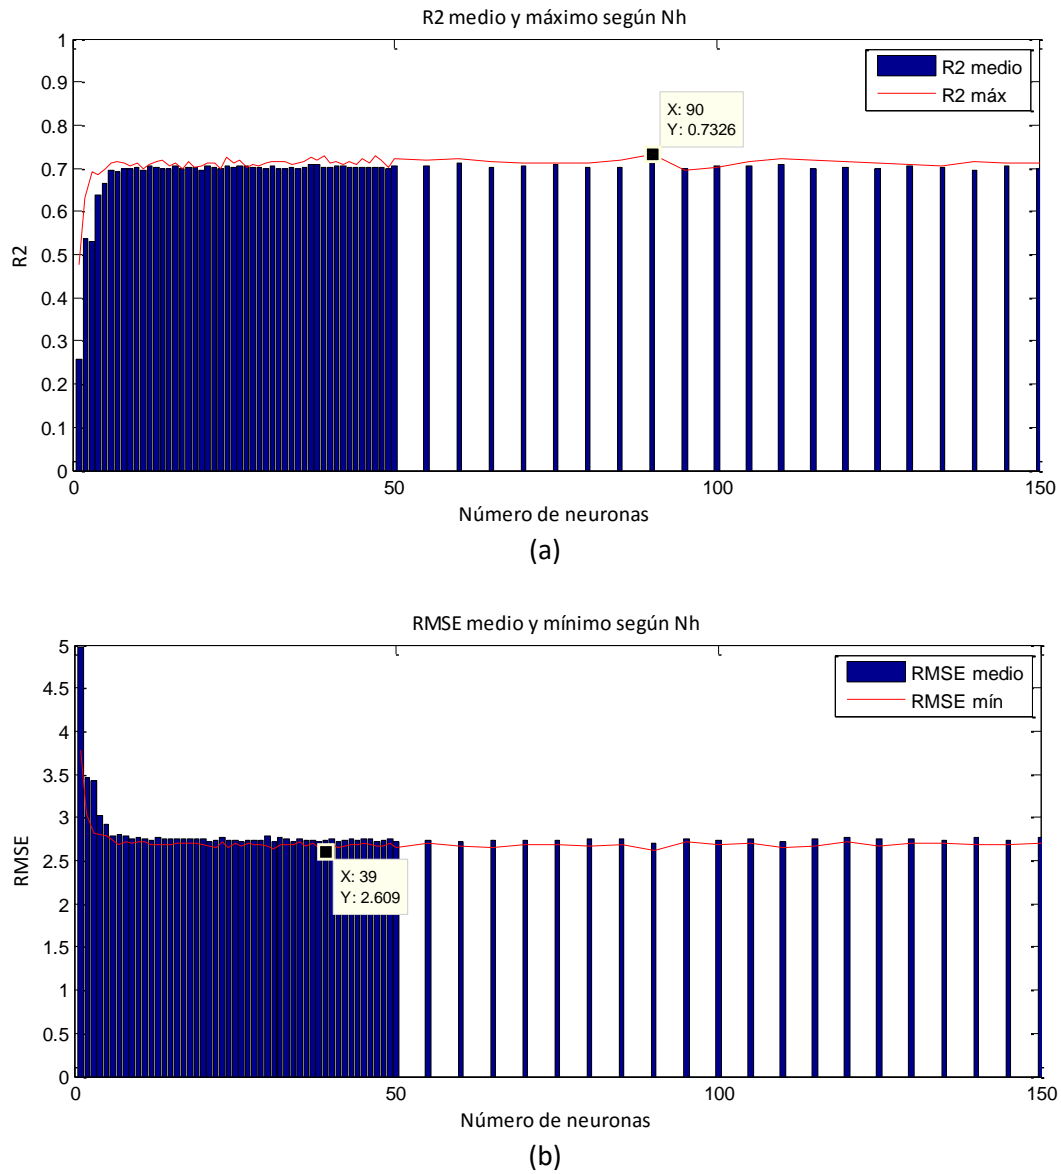


FIGURA 28. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA FIJA EXP. BASE.

En estas imágenes puede verse que los resultados apenas varían una vez alcanzan cierto valor de neuronas, en ambos casos podría decirse que los resultados prácticamente se estabilizan a partir de un número de neuronas superior a 9 o 10. En el rango de 10 a 150 neuronas, los valores obtenidos oscilan según los valores de la Tabla 10 y Tabla 11.

R2 medio		R2 máximo	
Min: 69.61%	Max: 71.14%	Min: 69.64%	Max: 73.26%

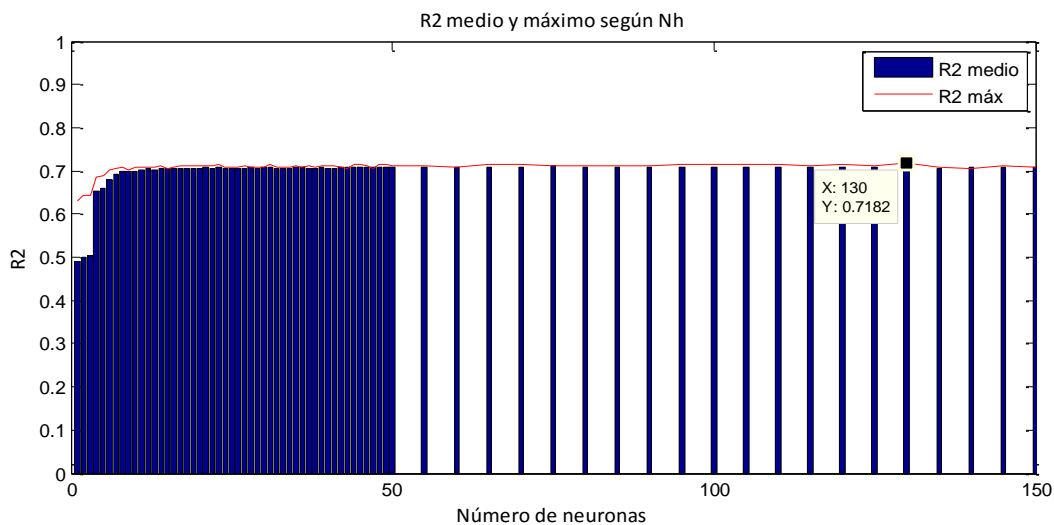
TABLA 10. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[10,150] CON VF EXP. BASE.

RMSE medio		RMSE mínimo	
Min: 2.70m/s	Max: 2.77m/s	Min: 2.60m/s	Max: 2.72m/s

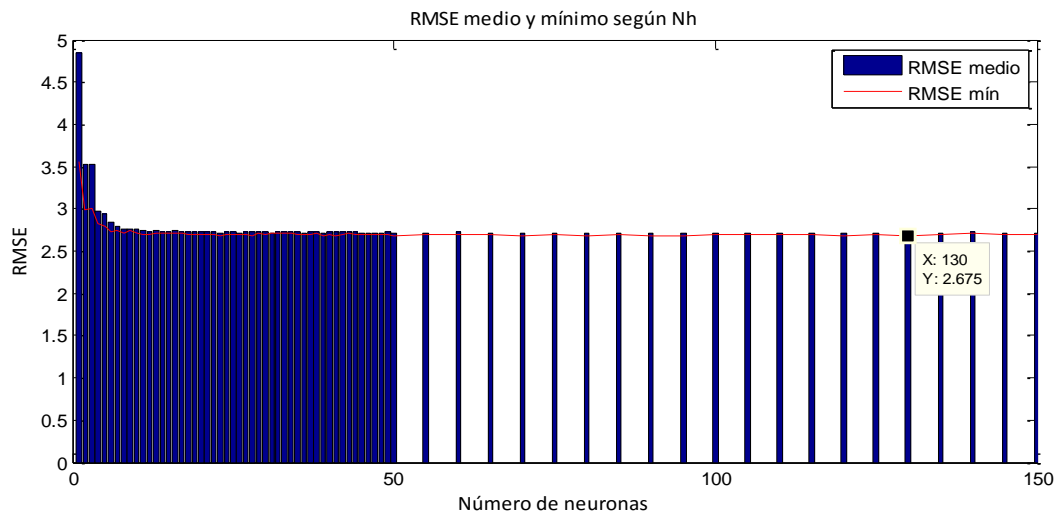
TABLA 11. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[10,150] CON VF EXP. BASE.

En las figuras aparece además indicado el número de neuronas que mejor resultado obtiene, en el caso de R² 90 neuronas, y de RMSE 39 neuronas.

➤ Ventana móvil.



(a)



(b)

FIGURA 29. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA MÓVIL EXP. BASE.

Al igual que sucede con ventana fija, los resultados prácticamente se estabilizan una vez alcanzan cierto valor de neuronas superior a 9 o 10. En el rango de 10 a 150 neuronas, los valores obtenidos oscilan según los valores de la Tabla 12 y Tabla 13.

R2 medio		R2 máximo	
Min: 70.02%	Max: 71.07%	Min: 70.48%	Max: 71.82%

TABLA 12. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[10,150] CON VM EXP. BASE.

RMSE medio		RMSE mínimo	
Min: 2.70m/s	Max: 2.75m/s	Min: 2.67m/s	Max: 2.71m/s

TABLA 13. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[10,150] CON VM EXP. BASE.

En las figuras aparece además indicado el número de neuronas que mejor resultado obtiene, tanto para R² como para RMSE con 130 neuronas.

PREDICCIÓN DE VELOCIDAD MÁXIMA EN LAS 6H SIGUIENTES: Resultado de predicción obtenido con el algoritmo ELM para distinto número de neuronas en la capa oculta: 10, 50, 100 y 150.

-----**VENTANA FIJA**-----

VENTANA FIJA		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
10	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>
50	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>

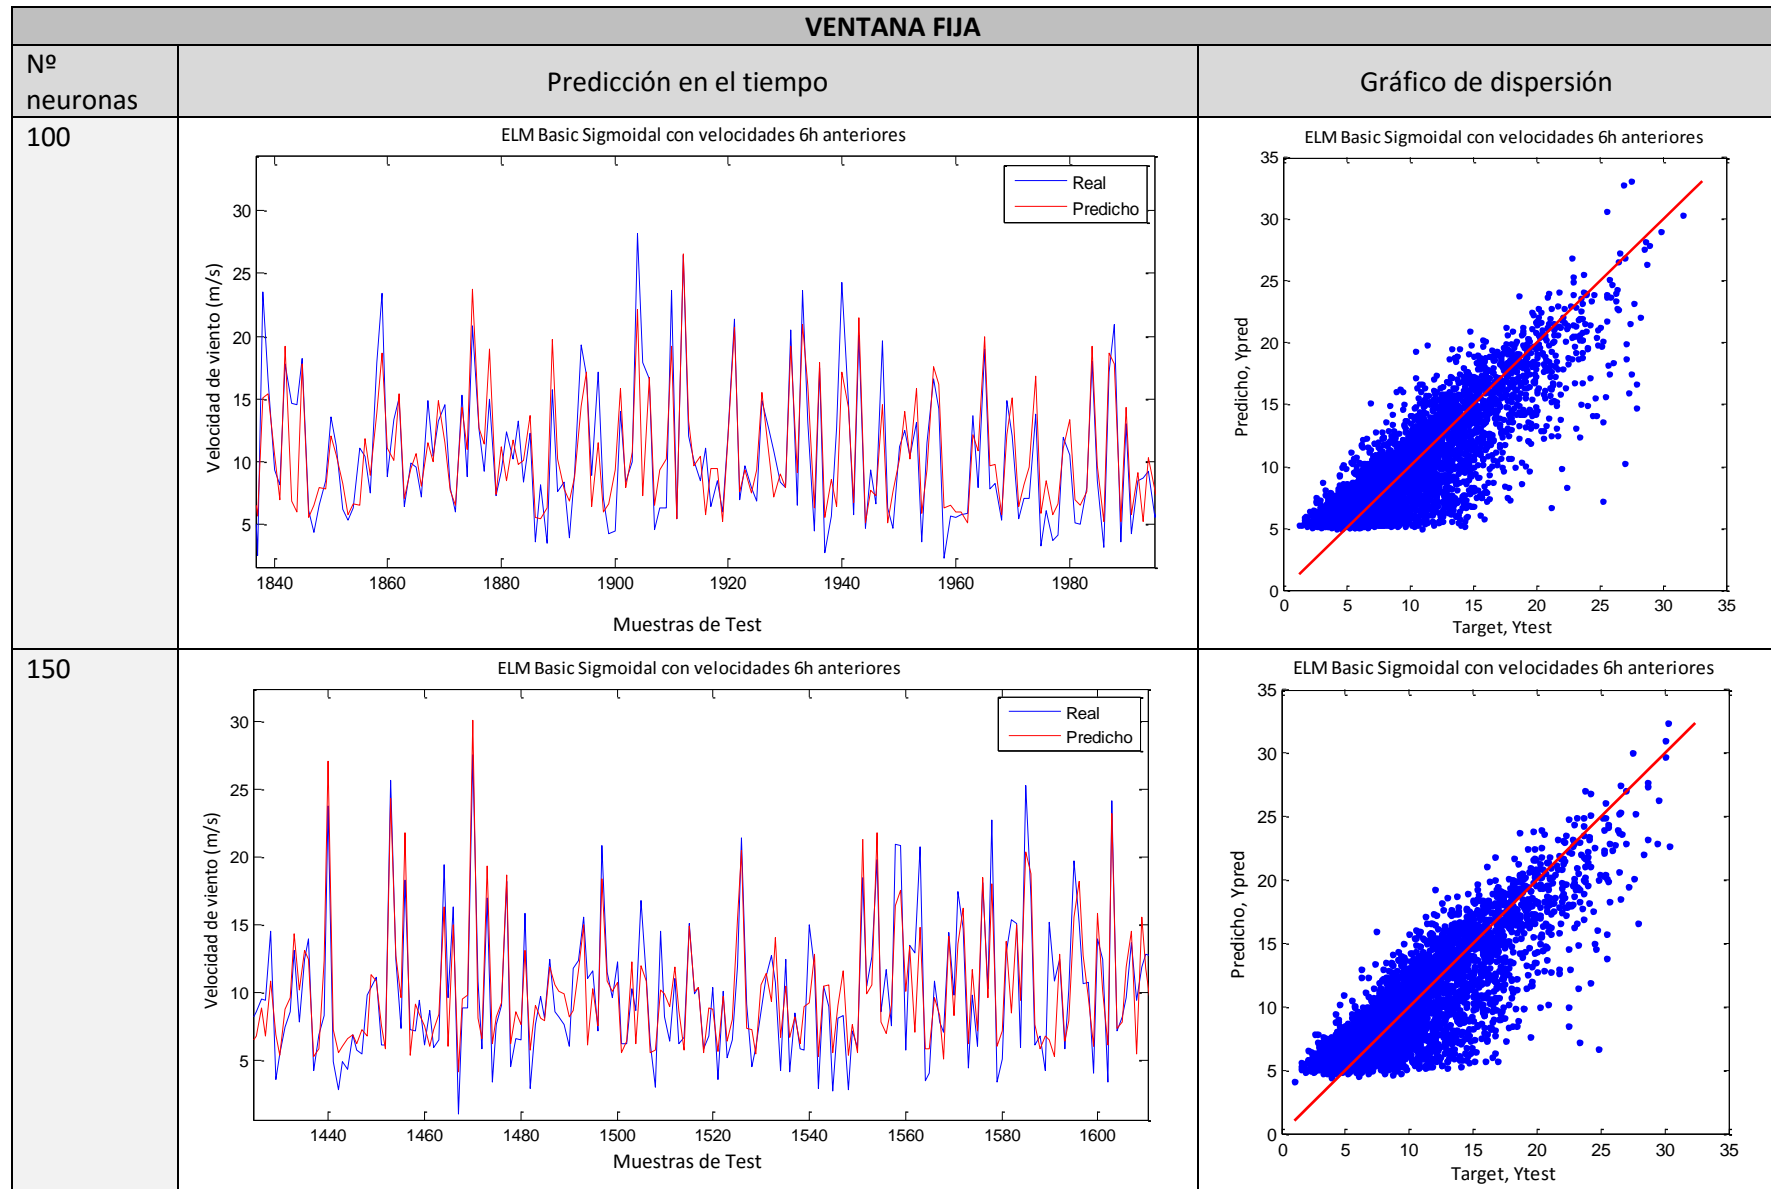


TABLA 14. RESULTADOS DE PREDICCIÓN CON VENTANA FIJA PARA EL EXP. BASE.

La Tabla 15 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 1: Resultados de predicción para Ventaja Fija y Atributos de velocidad				
Num. neuronas	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
10	71.48 %	70.37 %	2.68 m/s	2.73 m/s
50	71.91 %	70.72 %	2.59 m/s	2.71 m/s
100	71.99 %	70.15 %	2.67 m/s	2.74 m/s
150	72.03 %	69.98 %	2.66 m/s	2.73 m/s

TABLA 15. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA FIJA.

La gráfica de la Figura 30 ilustra estos resultados. Para sacar conclusiones sobre ellos debe tenerse en cuenta que con cierto número de neuronas puede haberse conseguido en una de las iteraciones el mejor resultado del experimento, pero eso no lo convierte en el mejor número de neuronas a escoger, ya que puede tener unos resultados medios mediocres. Es el caso de emplear 150 neuronas en la capa oculta, se ha obtenido en una de las iteraciones el mejor resultado encontrado para R^2 (72.03%), y sin embargo el valor medio de todas las iteraciones es el más bajo (69.98%).




FIGURA 30. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA FIJA.

Además, estos resultados son similares a la evaluación del error y del porcentaje de ajuste según el número de neuronas realizada anteriormente. En ella se obtenía un RMSE mínimo de 2.60 m/s con 39 neuronas, frente a 2.59 m/s con 50 neuronas en la Tabla 15, y un R^2 máximo de 73.26% con 90 neuronas, frente a 71.99% con 100 neuronas en la Tabla 15.

-----**VENTANA MÓVIL**-----

VENTANA MÓVIL		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
10	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>
50	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>

VENTANA MÓVIL		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
100	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>
150	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores</p>

TABLA 16. RESULTADOS DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. BASE.

La Tabla 17 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 1: Resultados de predicción para Ventaja Móvil y Atributos de velocidad				
Num. neuronas	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
10	70.54 %	69.81 %	2.71 m/s	2.75 m/s
50	71.40 %	70.77 %	2.69 m/s	2.71 m/s
100	71.68 %	70.86 %	2.69 m/s	2.71 m/s
150	71.72 %	70.90 %	2.68 m/s	2.71 m/s

TABLA 17. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA MÓVIL.

En este caso con ventana móvil se observa que los resultados, tanto en términos medios como en extremos, mejoran según aumenta el número de neuronas de la capa oculta, aunque el porcentaje de mejora con cada nueva simulación es menor según crece el número de neuronas de la capa oculta. Esta progresión puede verse también expresada en la gráfica de la Figura 31.




FIGURA 31. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO BASE CON VENTANA MÓVIL.

Los mejores resultados se han obtenido con 150 neuronas (71.72%, 2.68 m/s), valor que se aproxima al obtenido con las gráficas anteriores que representaban el error de predicción y el porcentaje de ajuste según el número de neuronas. En ellas se obtenía un RMSE mínimo con 130 neuronas, de 2.67 m/s, y un R^2 máximo también con 130 neuronas, de 71.82%, cercanos a los resultados presentados con 150 neuronas.

COMPARATIVA VENTANA FIJA Y VENTANA MÓVIL EXPERIMENTO 1:

El objetivo de emplear ventana móvil era poder disponer de un mayor número de ejemplos para entrenar al algoritmo y comprobar si consigue mejorar la predicción. Además, se ha realizado el diseño de la red neuronal con distintos valores de neuronas en la capa oculta para comprobar con cuál de ellos se obtiene un mayor rendimiento en el modelo.

En **ventana fija**, la solución que mejores valores medios presenta es aquella diseñada con **50 neuronas** en la capa oculta, ya que tiene el error medio más bajo, 2.71 m/s, y el porcentaje de ajuste medio más alto, 70.72%. Si aumenta el número de neuronas de la capa oculta por encima de 50 neuronas los resultados medios comienzan a empeorar considerablemente mientras que los resultados extremos apenas mejoran, por lo que puede concluirse que no siempre un aumento de neuronas en la capa oculta implica mejorar los resultados.

En el caso de **ventana móvil**, según aumenta el número de neuronas de la capa oculta, se producen mejoras tanto en resultados medios como extremos, aunque el porcentaje de mejora es cada vez menor. La solución que mejores resultados ha obtenido es aquella que emplea **150 neuronas** en la capa oculta, con un error medio de 2.71 m/s y un porcentaje de ajuste medio de 70.90%.

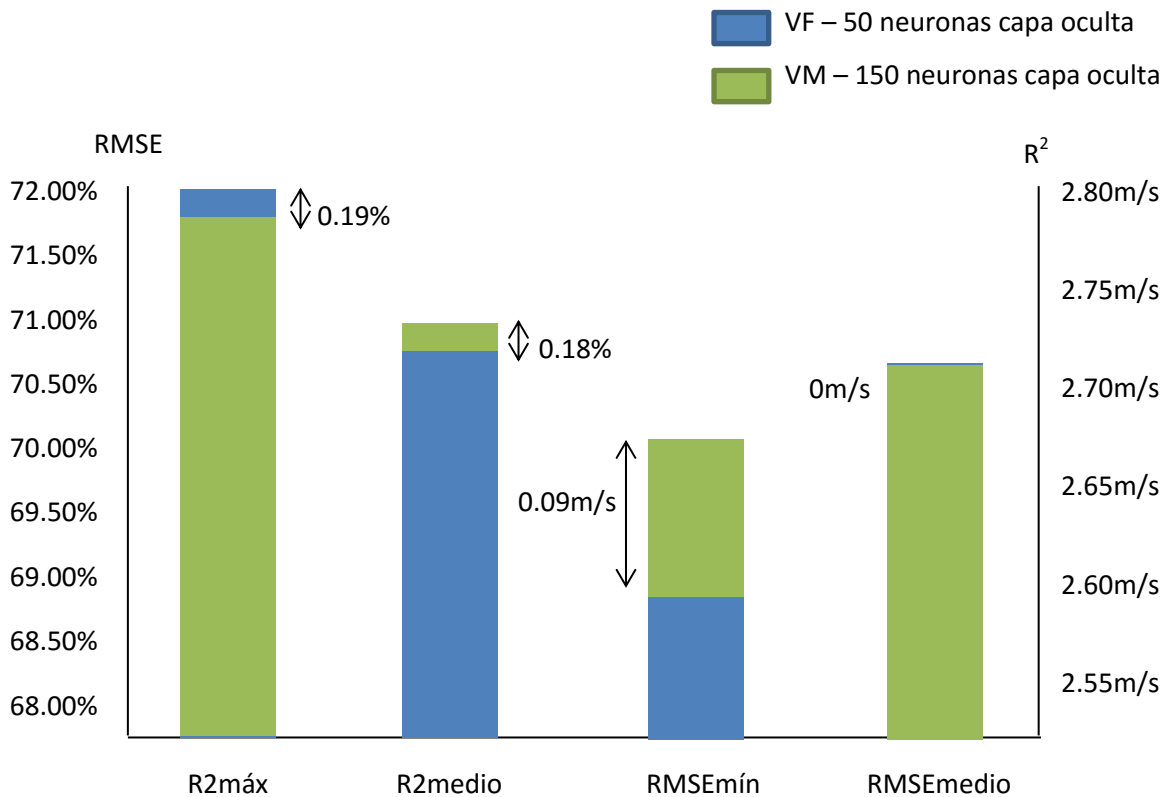


FIGURA 32. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO BASE PARA VENTANA FIJA VS VENTANA MÓVIL.

Realizando una comparativa en la gráfica de la Figura 32 de las dos mejores soluciones obtenidas en las simulaciones, con 50 neuronas para ventana fija y 150 neuronas para ventana móvil, se observa mejor resultado de predicción para los parámetros extremos ($R2_{\text{máx}}$ y $RMSE_{\text{mín}}$) con ventana fija, y mejor resultado para los parámetros medios ($R2_{\text{medio}}$ y $RMSE_{\text{medio}}$) con ventana móvil. La importancia realmente va a residir en los valores medios obtenidos con validación cruzada puesto que son éstos los que van a caracterizar realmente cómo se comporta de forma generalizada la red neuronal diseñada, por tanto se concluye que para el Experimento 1 el procesamiento de los datos con ventana móvil obtiene resultados mejores, aunque no significativos, frente a ventana fija.

4.4. EXPERIMENTO CON REANÁLISIS

OBJETIVO: A los ejemplos del Experimento 1, basado en predecir la velocidad máxima de viento en las 6h siguientes a partir de los datos de velocidad de viento de las 6h anteriores, se les añade el conjunto de datos de reanálisis obtenido de 4 estaciones cercanas al parque. Se añadirán, por tanto, 48 variables de entrada más al algoritmo ELM (12 por cada estación), y se tratará de predecir la velocidad máxima de viento en las 6h siguientes a partir de los datos de viento y de reanálisis de las 6h anteriores. El objetivo será obtener la salida de predicción de la red neuronal artificial entrenada y testada mediante el algoritmo ELM.

CONDICIONES:

1. Las variables de entrada se componen tanto de los 6 datos de velocidad de viento como de los 48 datos de reanálisis especificados en la Tabla 4.
2. Se utilizará validación cruzada aleatoria para entrenar y testear la red, con 10 iteraciones y proporción Train-Test 80-20%.

REQUISITOS INICIALES:

- Se deben cuadrar las matrices de atributos de velocidad, atributos de reanálisis y target. Será necesario eliminar la última ventana de atributos, ya que no dispone de 6 horas siguientes donde obtener el máximo, y, para el caso de ventana móvil, la primera ventana de atributos y target, ya que los datos de reanálisis comienzan en la hora 6 y la primera ventana (0-5h) llevará asignados los predictores de la hora más próxima, que es la hora 0.
- Una vez formado el conjunto [Target, Reanálisis, Atributos] será necesario eliminar aquellas ventanas no válidas, tal como se describió anteriormente.

MATRICES DE PARTIDA:

Ventana fija	Ventana móvil
Atributos [22078,6]; Reanálisis [22078,48]; Target [22078,1];	Atributos [132498,6]; Reanálisis [132498,48]; Target [132498,1];

TABLA 18. MATRICES VÁLIDAS PARA EL EXPERIMENTO CON REANÁLISIS.


VARIABLES DE ENTRADA: De acuerdo con la Tabla 4 de la sección 3.2, las variables de entrada empleadas en este experimento, compuestas por variables de velocidad de las 6h anteriores y las variables de reanálisis de la forma <<variable>>.X, siendo X el número de estación de medida, se presentan en la Tabla 19.

Vble. 1	Vble. 2	Vble. 3	Vble. 4	Vble. 5	Vble. 6	Vble. 7	Vble. 8	Vble. 9
v(t)	v(t-1)	v(t-2)	v(t-3)	v(t-4)	v(t-5)	skt.1	sp.1	u ₁₀ .1
Vble. 10	Vble. 11	Vble. 12	Vble. 13	Vble. 14	Vble. 15	Vble. 16	Vble. 17	Vble. 18
v ₁₀ .1	temp ₁ .1	up ₁ .1	vp ₁ .1	wp ₁ .1	temp ₂ .1	up ₂ .1	vp ₂ .1	wp ₂ .1
Vble. 19	Vble. 20	Vble. 21	Vble. 22	Vble. 23	Vble. 24	Vble. 25	Vble. 26	Vble. 27
skt.2	sp.2	u ₁₀ .2	v ₁₀ .2	temp ₁ .2	up ₁ .2	vp ₁ .2	wp ₁ .2	temp ₂ .2
Vble. 28	Vble. 29	Vble. 30	Vble. 31	Vble. 32	Vble. 33	Vble. 34	Vble. 35	Vble. 36
up ₂ .2	vp ₂ .2	wp ₂ .2	skt.3	sp.3	u ₁₀ .3	v ₁₀ .3	temp ₁ .3	up ₁ .3
Vble. 37	Vble. 38	Vble. 39	Vble. 40	Vble. 41	Vble. 42	Vble. 43	Vble. 44	Vble. 45
vp ₁ .3	wp ₁ .3	temp ₂ .3	up ₂ .3	vp ₂ .3	wp ₂ .3	skt.4	sp.4	u ₁₀ .4
Vble. 46	Vble. 47	Vble. 48	Vble. 49	Vble. 50	Vble. 51	Vble. 52	Vble. 53	Vble. 54
v ₁₀ .4	temp ₁ .4	up ₁ .4	vp ₁ .4	wp ₁ .4	temp ₂ .4	up ₂ .4	vp ₂ .4	wp ₂ .4

TABLA 19. CARACTERÍSTICAS DE ENTRADA PARA EL EXPERIMENTO CON REANÁLISIS

EVALUACIÓN DEL NÚMERO DE NEURONAS DE LA CAPA OCULTA: A continuación se muestran los resultados obtenidos tanto para los mejores valores de RMSE y R² como para sus valores medios, con el objetivo de comprobar cómo afecta el número de neuronas de la capa oculta al diseño de la red neuronal en el Experimento con reanálisis.

➤ Ventana fija.



(a)




FIGURA 33. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA FIJA EXP. CON REANÁLISIS.

En estas imágenes puede verse que los resultados mejoran lentamente una vez alcanzan un número de neuronas superior a 20, y, aunque no varía demasiado, el incremento (o decremento en caso del error) según aumenta el número de neuronas de la capa oculta es mayor que el observado cuando se tenían exclusivamente datos de velocidad en las variables de entrada.

En este rango de 20 a 150 neuronas, los valores obtenidos oscilan según los valores de la Tabla 20 y Tabla 21.

R2 medio		R2 máximo	
Min: 69.74%	Max: 74.55%	Min: 69.25%	Max: 75.77%


TABLA 20. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[20,150] CON VF EXP. CON REANÁLISIS.

RMSE medio		RMSE mínimo	
Min: 2.53m/s	Max: 2.76m/s	Min: 2.47m/s	Max: 2.69m/s


TABLA 21. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[20,150] CON VF EXP. CON REANÁLISIS.

En las figuras aparece además indicado el número de neuronas que mejor resultado obtiene, en el caso de R² 120 neuronas, y de RMSE 150 neuronas.

➤ Ventana móvil.



(a)



(b)

FIGURA 34. EVOLUCIÓN DE R2 (A) Y RMSE (B) EN FUNCIÓN DEL NÚMERO DE NEURONAS PARA VENTANA MÓVIL EXP. CON REANÁLISIS.

De igual manera se aprecia cómo el aumento de neuronas mejora los resultados aunque cada vez más lentamente a partir de las 20 neuronas. Además, el incremento (o decremento en caso del error) según aumenta el número de neuronas es mayor que el observado cuando se tenían exclusivamente datos de velocidad en las variables de entrada.

En este rango de 20 a 150 neuronas, los valores obtenidos oscilan según los valores de la Tabla 22 y Tabla 23.

R2 medio		R2 máximo	
Min: 69.23%	Max: 72.49%	Min: 70.93%	Max: 72.91%

TABLA 22. VALORES MEDIOS Y MÁXIMOS DE R2 PARA NH=[20,150] CON VM EXP. CON REANÁLISIS.

RMSE medio		RMSE mínimo	
Min: 2.63m/s	Max: 2.80m/s	Min: 2.60m/s	Max: 2.72m/s

TABLA 23. VALORES MEDIOS Y MÁXIMOS DE RMSE PARA NH=[20,150] CON VM EXP. CON REANÁLISIS.

En las figuras aparece además indicado el número de neuronas que mejor resultado obtiene, tanto para R² como para RMSE se alcanza con 140 neuronas.

PREDICCIÓN DE VELOCIDAD MÁXIMA EN LAS 6H SIGUIENTES: Resultado de predicción obtenido con el algoritmo ELM para distinto número de neuronas en la capa oculta: 20, 50, 100 y 150.

-----VENTANA FIJA-----

VENTANA FIJA		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
20	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>
50	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>

VENTANA FIJA		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
100	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>
150	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>

TABLA 24. RESULTADOS DE PREDICCIÓN CON VENTAJA FIJA PARA EL EXP. CON REANÁLISIS.

La Tabla 25 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 2: Resultados de predicción para Ventaja Fija y Atributos de velocidad y reanálisis				
Num. neuronas	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
20	71.81 %	69.78 %	2.67 m/s	2.76 m/s
50	72.54 %	71.51 %	2.64 m/s	2.68 m/s
100	73.96 %	72.86 %	2.56 m/s	2.62 m/s
150	75.12 %	73.96 %	2.49 m/s	2.55 m/s

TABLA 25. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA FIJA.

La gráfica de la Figura 35 ilustra estos resultados. En esta ocasión se puede ver que los resultados mejoran considerablemente según aumenta el número de neuronas. El porcentaje de ajuste R^2 crece tanto en valor máximo como en valor medio, y el error decrece de la misma manera, obteniéndose los mejores resultados en la red diseñada con 150 neuronas en la capa oculta, con un error medio de 2.55 m/s y un porcentaje de ajuste medio de 73.96%.


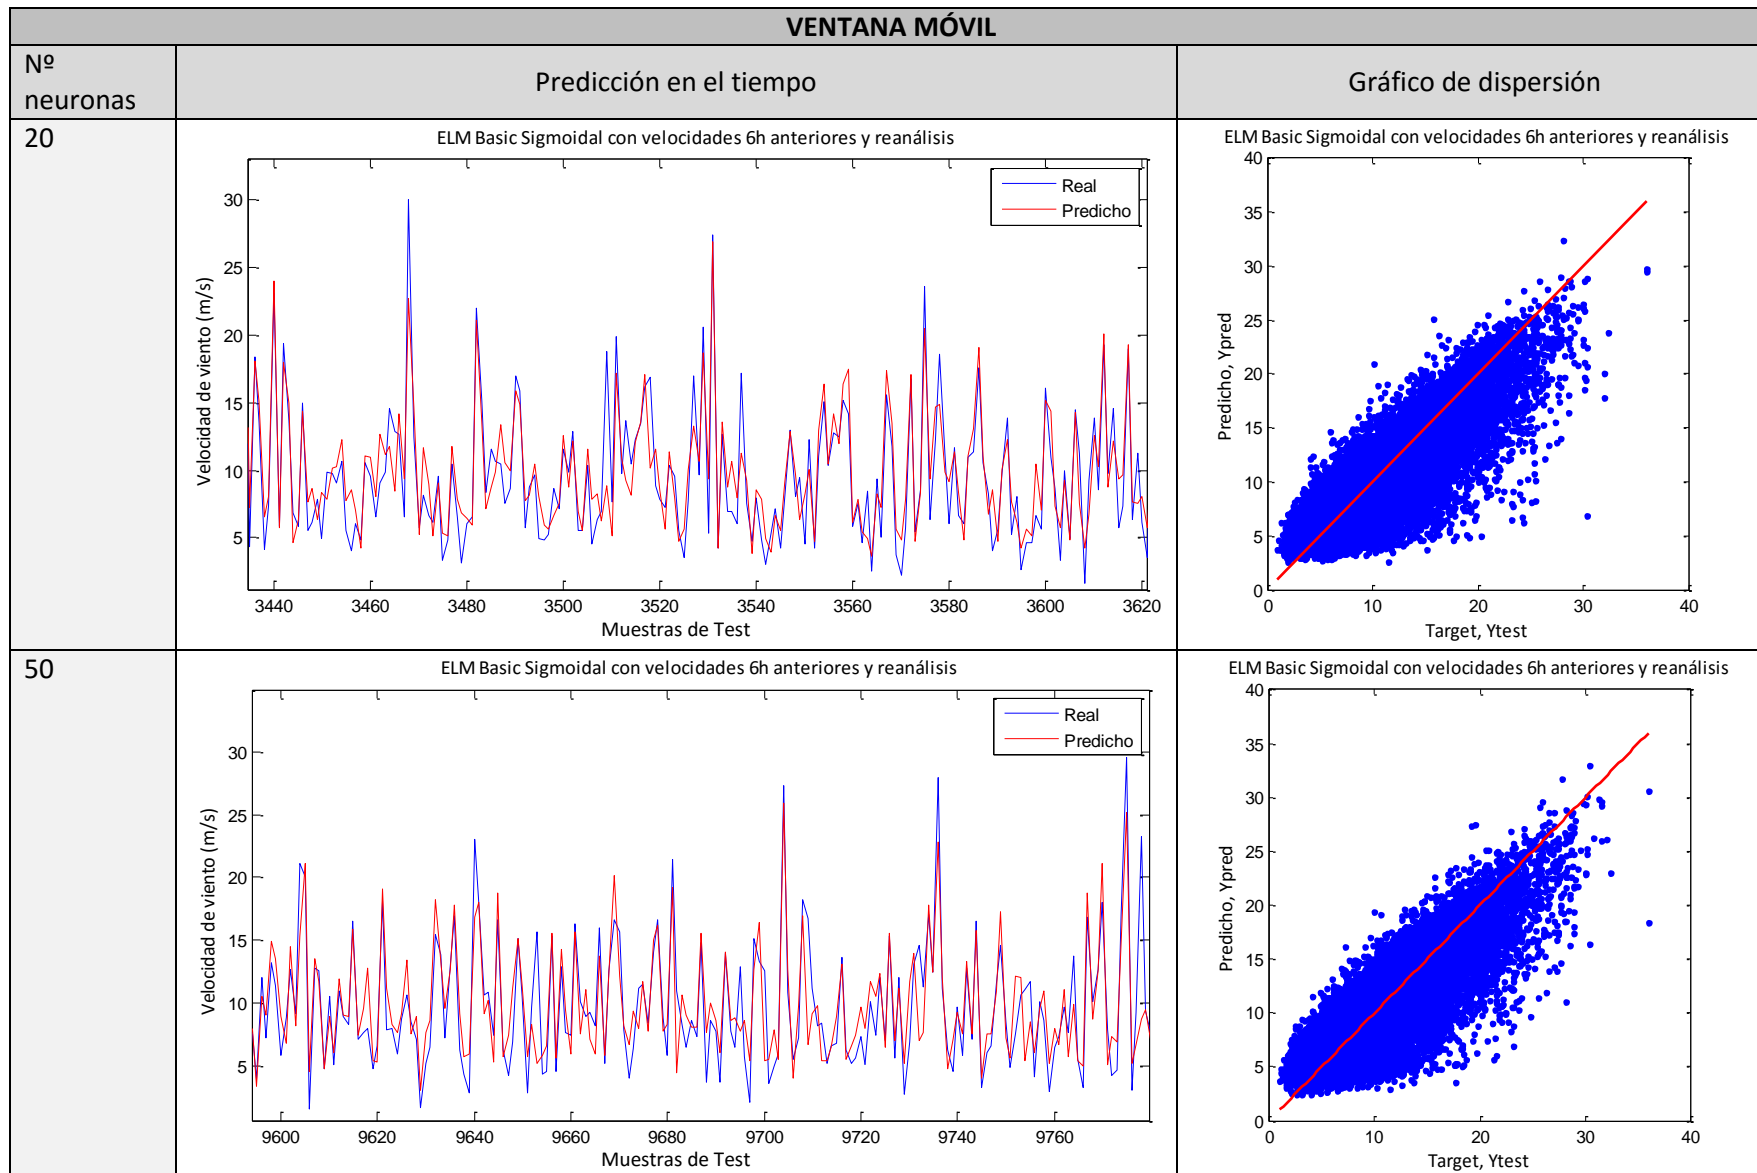


FIGURA 35. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA FIJA.

Comparando estos resultados con la evaluación del error y del porcentaje de ajuste según el número de neuronas realizada anteriormente, en ella se obtenía un RMSE mínimo con 150 neuronas de 2.47 m/s, frente a 2.49m/s en la Tabla 25, y un R^2 máximo con 120 neuronas de 75.77%, frente a 75.12% en la Tabla 25.



VENTANA MÓVIL		
Nº neuronas	Predicción en el tiempo	Gráfico de dispersión
100	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>
150	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>	<p>ELM Basic Sigmoidal con velocidades 6h anteriores y reanálisis</p>

TABLA 26. RESULTADOS DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. CON REANÁLISIS.

La Tabla 27 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 2: Resultados de predicción para Ventaja Móvil y Atributos de velocidad y reanálisis				
Num. neuronas	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
20	70.93 %	69.81 %	2.70 m/s	2.76 m/s
50	72.08 %	71.65 %	2.66 m/s	2.68 m/s
100	72.45 %	72.01 %	2.63 m/s	2.65 m/s
150	72.70 %	72.32 %	2.61 m/s	2.63 m/s

TABLA 27. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA MÓVIL.

La gráfica de la Figura 36 ilustra estos resultados. Puede verse que el mayor cambio se produce al aumentar a 50 el número de neuronas de la capa oculta. Posteriormente según se emplea mayor número de neuronas mejoran los resultados pero de forma más lenta. El porcentaje de ajuste R^2 crece tanto en valor máximo como en valor medio, y el error decrece de la misma manera, obteniéndose los mejores resultados en la red diseñada con 150 neuronas en la capa oculta, con un error medio de 2.63 m/s y un porcentaje de ajuste medio de 72.32%.




FIGURA 36. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON REANÁLISIS CON VENTANA MÓVIL.

Estos resultados se asemejan a la evaluación del error y del porcentaje de ajuste según el número de neuronas realizada anteriormente. En ella se obtenían los mejores resultados con 140 neuronas, siendo un RMSE mínimo de 2.60 m/s y un R^2 máximo de 72.91%, cercanos a los resultados para 150 neuronas (2.61 m/s y 72.70%).

COMPARATIVA VENTANA FIJA Y VENTANA MÓVIL EXPERIMENTO 2:

El objetivo para este experimento es comprobar cómo afecta a los resultados incluir variables de entrada provenientes de un dataset de reanálisis, en concreto 48 variables de reanálisis identificadas en la Tabla 4. A la vista de los resultados del Experimento con reanálisis, puede concluirse que, tanto para ventana fija como para ventana móvil, los resultados de las simulaciones mejoran al introducir en el experimento las características de reanálisis proporcionadas en comparación con los resultados obtenidos empleando únicamente como características los datos de velocidad de viento de las 6 horas anteriores. Además, en el Experimento base sucedía que para ventana fija los resultados medios no mejoraban con el aumento de neuronas en la capa oculta, como sí sucede en el Experimento con reanálisis. A continuación se va a realizar una comparativa de los mejores resultados obtenidos para cada tipo de ventana en estos experimentos:

- Con **ventana fija**, la mejor solución obtenida en el Experimento con reanálisis es aquella diseñada con 150 neuronas en la capa oculta. Ésta se comparará tanto en valores medios como extremos con la solución que mejores valores medios presentaba en el Experimento base, aquella diseñada con 50 neuronas en la capa oculta.




FIGURA 37. COMPARATIVA EXPERIMENTO BASE Y EXPERIMENTO CON REANÁLISIS PARA VENTANA FIJA.

Para el caso de emplear ventana fija, al incluir los datos de reanálisis, los resultados de simulación mejoran, especialmente para el porcentaje de ajuste R^2 donde se obtienen valores en torno a un 3% superiores.

- Con **ventana móvil**, sucede tanto en el Experimento base como en el Experimento con reanálisis que la mejor solución se obtiene diseñando la red con 150 neuronas en la capa oculta, tanto a nivel de resultados medios como extremos. Se compararán ambas soluciones para observar el grado de mejora de los resultados con el Experimento con reanálisis.




FIGURA 38. COMPARATIVA EXPERIMENTO BASE Y EXPERIMENTO CON REANÁLISIS PARA VENTANA MÓVIL.

Para el caso de emplear ventana móvil, al incluir los datos de reanálisis, los resultados de predicción también mejoran aunque en menor medida que para ventana fija. Se nota como principal mejora el aumento del porcentaje de ajuste R^2 medio, donde se ha obtenido un valor un 1.42% mayor.

Queda claro que el haber incorporado el dataset de reanálisis al experimento ha contribuido a mejorar los resultados de predicción para ambos casos de ventana fija y ventana móvil. Conviene ahora realizar una comparativa dentro de este experimento para determinar con cuál de estas ventanas se obtienen mejores resultados.

Para ello, el gráfico de la Figura 39 muestra una comparativa de las dos ventanas para el caso de 150 neuronas en la capa oculta que donde mejores resultados de predicción se obtienen para ambos casos.




FIGURA 39. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO CON REANÁLISIS PARA VENTANA FIJA VS VENTANA MÓVIL.

A la vista de la comparativa de la gráfica de la Figura 39 se observan mejores resultados con ventana fija, tanto para valores medios como extremos, aunque, tal como se dijo en el Experimento base, son los valores medios los que determinan la calidad de la solución y donde más atención se debe prestar. Por tanto se concluye que, para este experimento que incluye el conjunto de características de reanálisis, el procesamiento de los datos con ventana fija obtiene resultados considerablemente mejores frente a ventana móvil, al contrario que sucedía en el Experimento base donde se obtenía ligeramente mejor rendimiento del modelo con ventana móvil.

4.5. EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS

OBJETIVO: Comprobar si se produce una mejora en la predicción al emplear sólo las variables de entrada seleccionadas por el algoritmo genético como variables esenciales para obtener el target asociado. El algoritmo genético evolucionará una población inicial compuesta por individuos que representan soluciones de combinaciones de atributos de velocidad y atributos de reanálisis de las 6h anteriores. El objetivo será obtener la salida de predicción de la red neuronal artificial entrenada y testeada mediante el algoritmo ELM.

CONDICIONES:

1. Las variables de entrada se componen de las características tanto de velocidad de viento como de reanálisis seleccionadas por el GA. Además, se han llevado a cabo varias ejecuciones del algoritmo evolutivo y las características seleccionadas varían de una a otra, por lo que el resultado final será la media de los resultados de todas ellas.
2. Se utilizará validación cruzada aleatoria para entrenar y testear la red, con 10 iteraciones y proporción Train-Test 80-20%.
3. El conjunto de datos original será repartido en Train y Test de forma que sólo se empleará el conjunto de Train para la selección de características en el GA, y se reservará el conjunto de Test para la evaluación del error de predicción final, una vez seleccionadas las características.
4. El algoritmo genético se ha diseñado con una población de 100 individuos. Su función fitness subdivide el conjunto de Train para entrenar y testear la red con las características de cada individuo, y asigna como fitness el error de validación de la red. El operador de cruce está basado en dos puntos y la probabilidad de mutación es del 5% con porcentaje de genes a mutar del 30%. Se dejará evolucionar un número elevado de generaciones o hasta comprobar que una misma solución resulta escogida a lo largo de numerosas generaciones.
5. El algoritmo ELM final se ejecutará con 150 neuronas en la capa oculta al haber sido éste el número que mejor resultados ha obtenido en el Experimento con reanálisis.

REQUISITOS INICIALES:

- Se deben cuadrar las matrices de atributos de velocidad, atributos de reanálisis y target. Este procedimiento es el mismo que se hizo para el Experimento con reanálisis.
- Una vez formado el conjunto [Target, Atributos, Reanálisis,] será necesario eliminar aquellas ventanas no válidas, tal como se describió anteriormente.
- Ejecutar en primer lugar el algoritmo genético hasta cumplir la condición de terminación.
- Ejecutar después la ELM final filtrando las características que han resultado seleccionadas.

MATRICES DE PARTIDA (equivalentes a las matrices del Experimento con reanálisis):

Ventana fija	Ventana móvil
Atributos [22078,6]; Reanálisis [22078,48]; Target [22078,1];	Atributos [132498,6]; Reanálisis [132498,48]; Target [132498,1];

TABLA 28. MATRICES VÁLIDAS PARA EL EXPERIMENTO CON SELECCIÓN DE CARACTERÍSTICAS.


PREDICCIÓN DE VELOCIDAD MÁXIMA EN LAS 6H SIGUIENTES: Resultado de predicción para 150 neuronas en la capa oculta y empleando las variables de entrada seleccionadas por el GA.

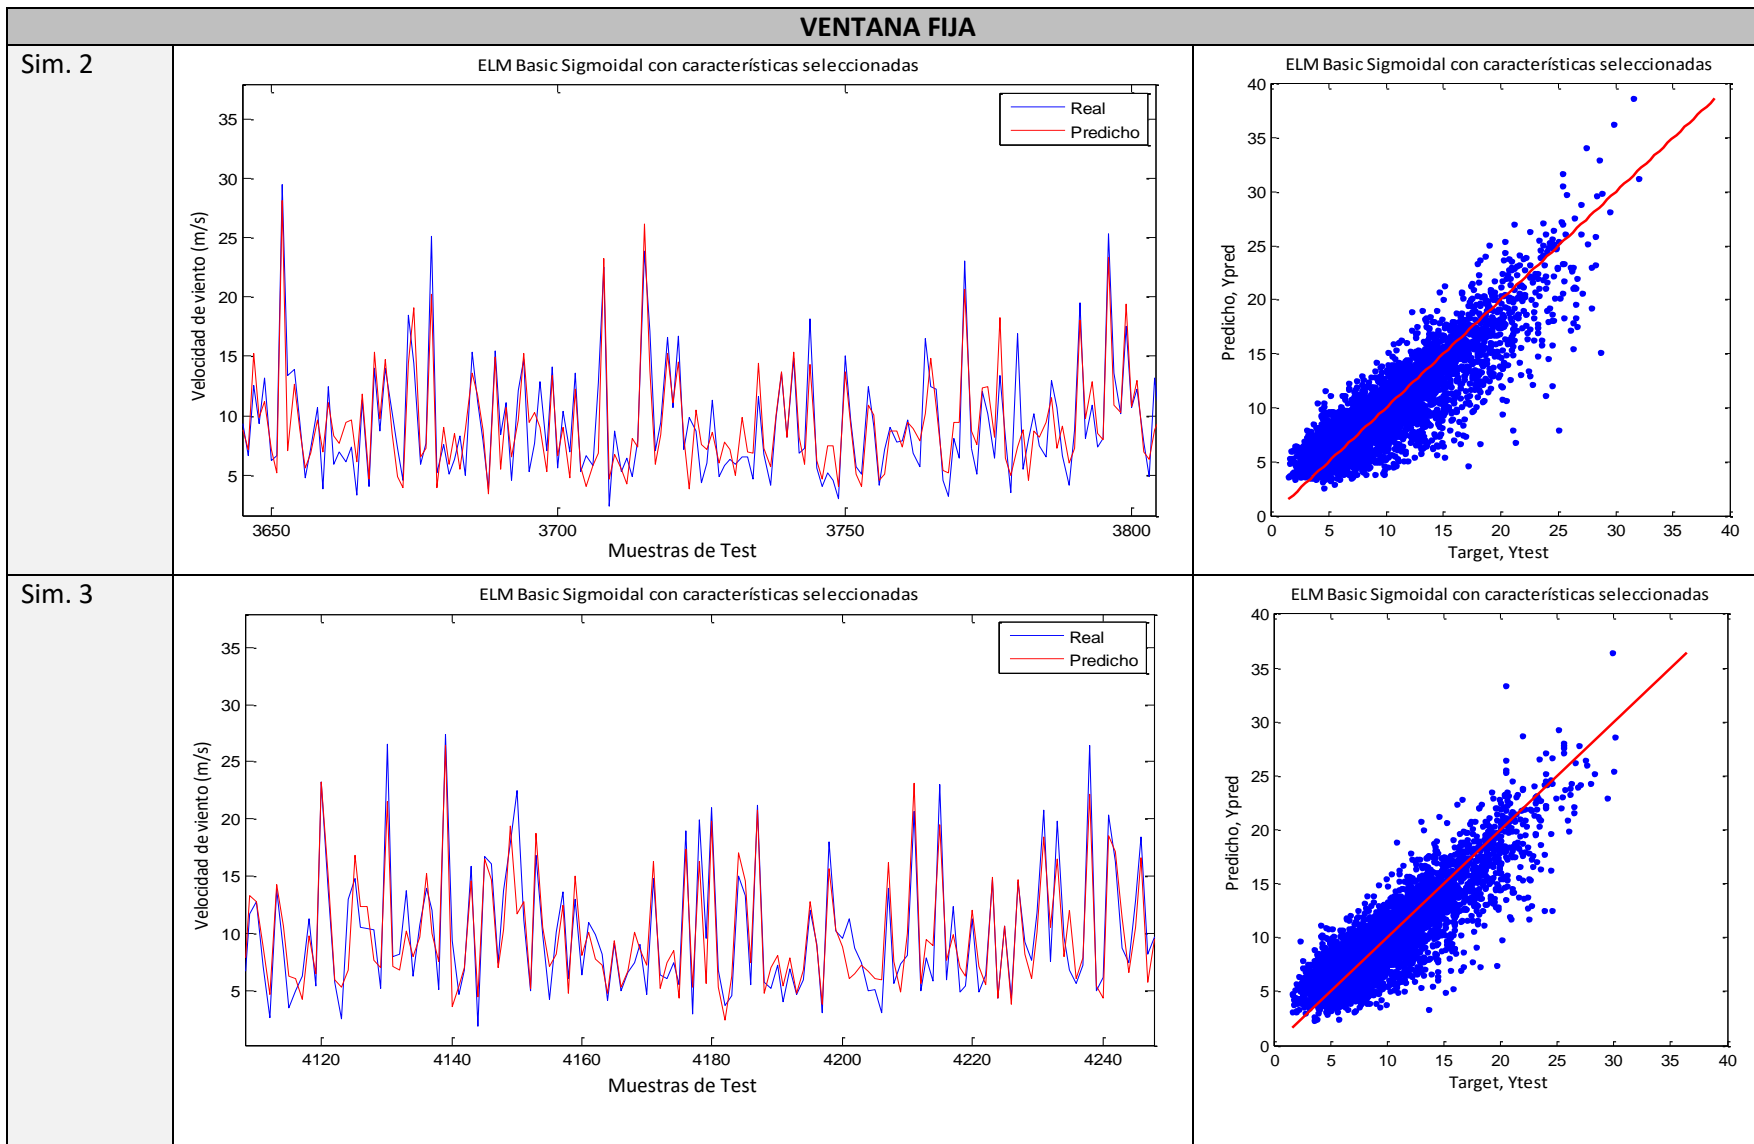
-----VENTANA FIJA-----

Características seleccionadas en cada una de las simulaciones del Algoritmo Genético para ventana fija:

Simulaciones	Mejor fitness encontrado	Características seleccionadas
1	2.40 m/s	[1,2,9,12,15,16,17,27,29,36,39,40,41,42,45,48,50,51,53]
2	2.412 m/s	[1,2,9,11,13,15,17,18,19,21,23,27,28,29,30,36,40,41,43,46,48,49,51,53,54]
3	2.428 m/s	[1,2,9,12,15,16,17,18,21,28,29,36,39,40,41,42,45,47,51,53,54]
4	2.405 m/s	[1,2,7,9,12,13,15,17,18,21,25,27,28,29,37,39,40,41,42,48,49,51,53,54]
5	2.412 m/s	[1,2,5,9,15,16,21,26,27,29,30,39,40,41,42,43,48,53,54]

TABLA 29. CARACTERÍSTICAS SELECCIONADAS POR EL ALGORITMO GENÉTICO PARA VENTANA FIJA Y ERROR MÍNIMO ASOCIADO AL INDIVIDUO.





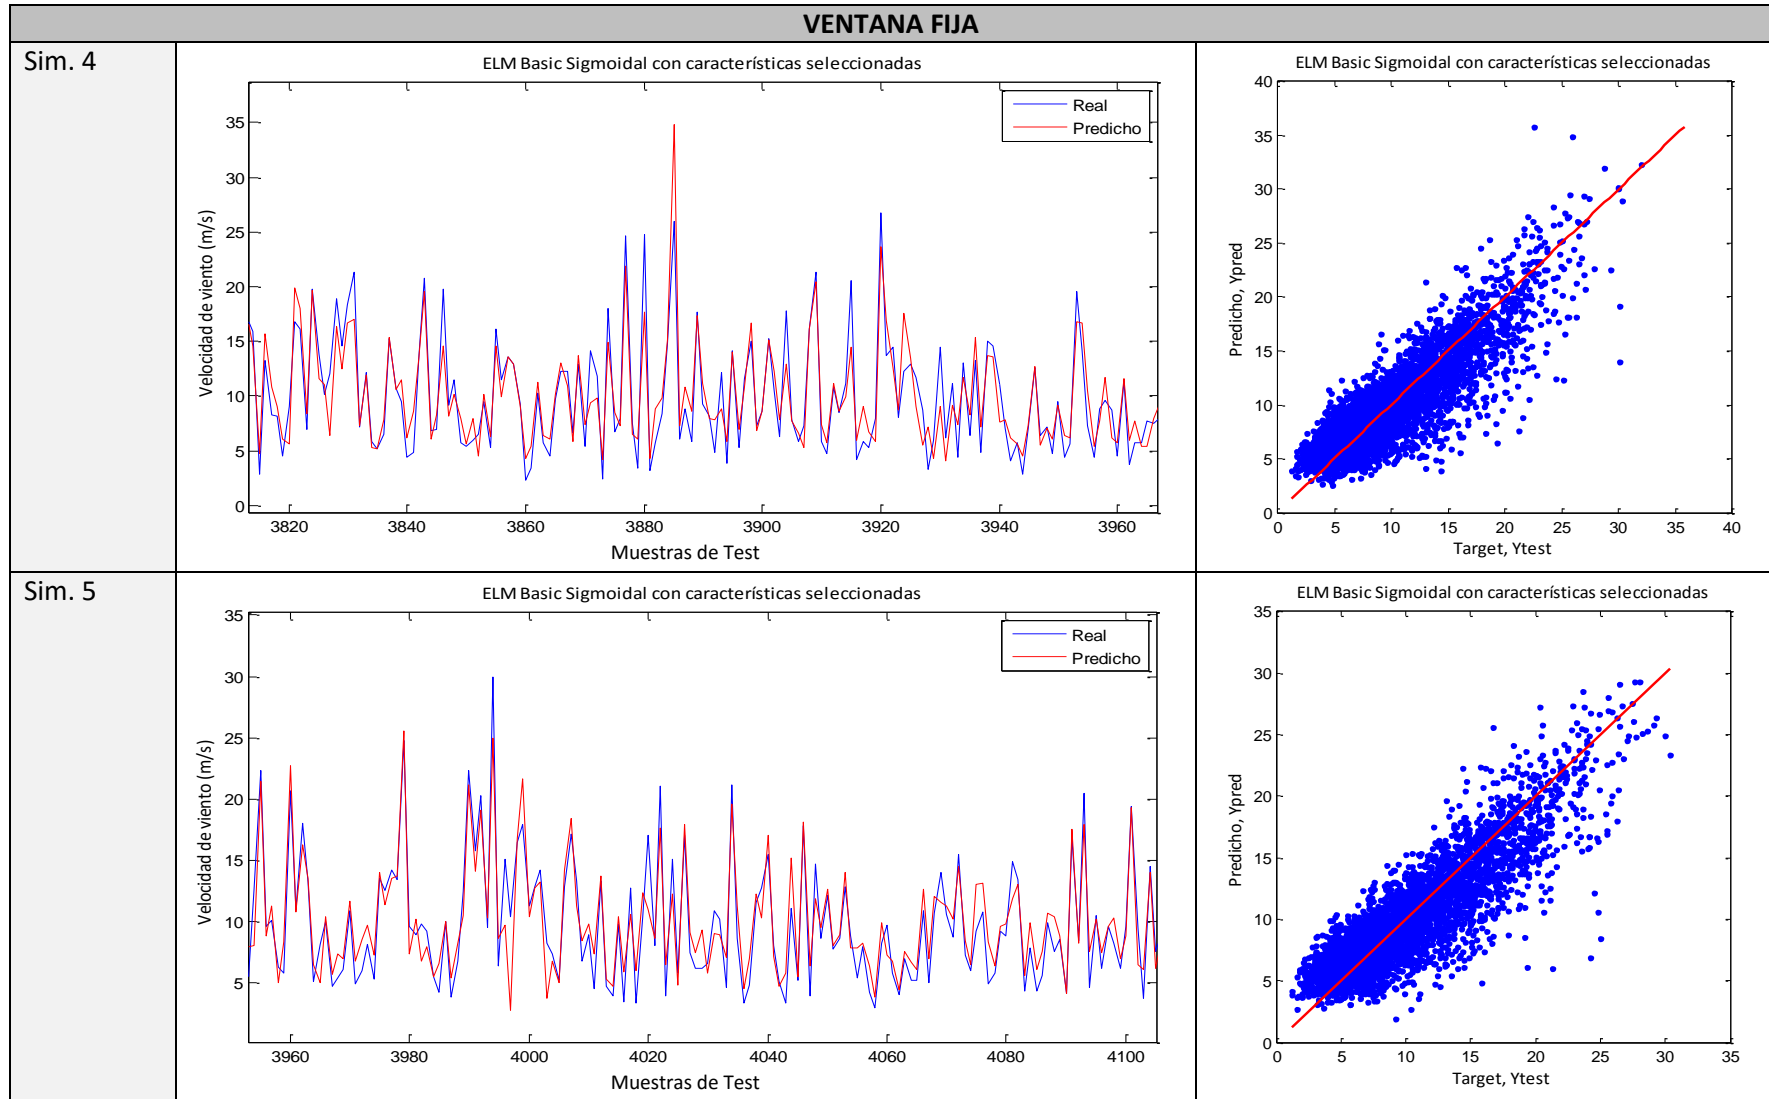


TABLA 30. RESULTADO DE PREDICCIÓN CON VENTANA FIJA PARA EL EXP. CON SELECCIÓN.

La Tabla 31 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 3: Resultados de predicción para Ventaja Fija y Atributos de velocidad y de reanálisis seleccionados				
Simulaciones	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
1	74.92 %	74.76 %	2.53 m/s	2.53 m/s
2	75.51 %	75.36 %	2.51 m/s	2.51 m/s
3	75.93 %	75.76 %	2.37 m/s	2.37 m/s
4	74.77 %	74.47 %	2.50 m/s	2.52 m/s
5	75.86 %	75.59 %	2.45 m/s	2.46 m/s
MEDIA	75.40 %	75.18 %	2.47 m/s	2.47 m/s

TABLA 31. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON SELECCIÓN CON VENTANA FIJA.

El gráfico de la Figura 40 muestra la comparativa en términos de R^2 y RMSE entre los resultados obtenidos sin selección de características en el Experimento con reanálisis para ventana fija y 150 neuronas en la capa oculta, y los resultados medios obtenidos seleccionando características previamente con el algoritmo genético en este experimento. Principalmente lo que consigue la selección de características para este caso con ventana fija es mejorar los resultados medios, consiguiendo un aumento del 1.22% en la media de R^2 y un descenso del error medio de 0.08m/s.





FIGURA 40. COMPARATIVA EXPERIMENTO CON REANÁLISIS Y EXPERIMENTO CON SELECCIÓN PARA VENTANA FIJA.

-----VENTANA MÓVIL-----

Características seleccionadas en cada una de las simulaciones del Algoritmo Genético para ventana móvil:



Simulaciones	Mejor fitness encontrado	Características seleccionadas
1	2.606 m/s	[1,2,3,6,10,12,13,14,15,17,18,21,22,25,28,29,30,31,32,36,39,40,42,43,44,47,48,50,52,54]
2	2.602 m/s	[1,2,6,8,10,13,16,17,18,19,20,21,24,26,28,29,31,33,34,35,37,38,40,41,42,45,48,49,50,52,53,54]
3	2.605 m/s	[1,2,5,8,9,10,12,13,14,15,16,17,18,21,23,28,32,38,40,41,42,44,45,48,49,51,52,53,54]
4	2.605 m/s	[1,2,5,11,12,15,16,17,18,19,25,32,37,39,40,41,42,43,44,45,46,48,49,51,52,53,54]
5	2.609 m/s	[1,2,5,12,13,15,17,18,19,20,21,26,28,32,34,37,39,40,41,42,44,45,47,48,51,52,53,54]

TABLA 32. CARACTERÍSTICAS SELECCIONADAS POR EL ALGORITMO GENÉTICO PARA VENTANA MÓVIL Y ERROR MÍNIMO ASOCIADO AL INDIVIDUO.





VENTANA MÓVIL

Sim. 2



Sim. 3



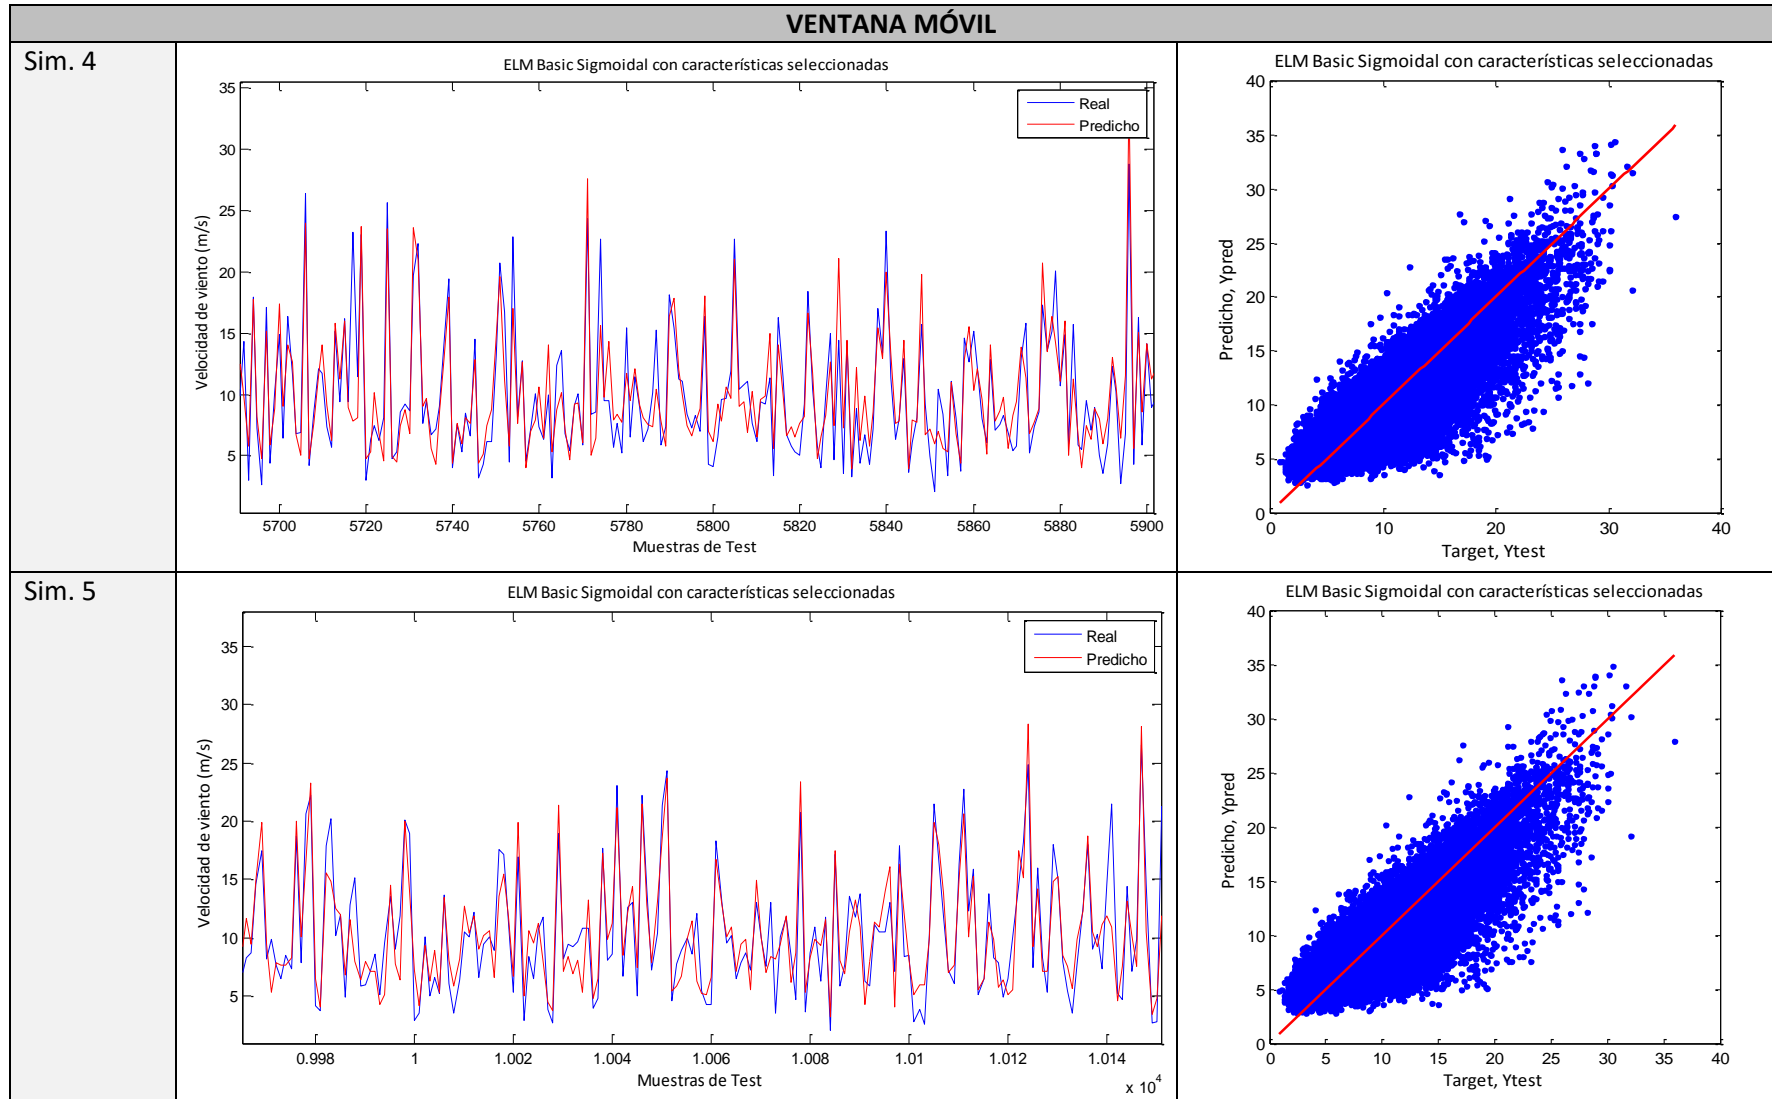


TABLA 33. RESULTADO DE PREDICCIÓN CON VENTANA MÓVIL PARA EL EXP. CON SELECCIÓN.

La Tabla 34 recoge los resultados de los valores RMSE y R^2 de este experimento correspondientes a las simulaciones presentadas en las gráficas anteriores:

EXP 3: Resultados de predicción para Ventaja Móvil y Atributos de velocidad y de reanálisis seleccionados				
Simulaciones	R2 máximo	R2 medio	RMSE mínimo	RMSE medio
1	72.70 %	72.59 %	2.61 m/s	2.62 m/s
2	72.23 %	72.11 %	2.64 m/s	2.64 m/s
3	72.69 %	72.56 %	2.62 m/s	2.63 m/s
4	72.65 %	72.56 %	2.62 m/s	2.63 m/s
5	72.63 %	72.53 %	2.62 m/s	2.63 m/s
MEDIA	72.58 %	72.47 %	2.62 m/s	2.63 m/s

TABLA 34. RESULTADOS DE PREDICCIÓN PARA EL EXPERIMENTO CON SELECCIÓN CON VENTANA MÓVIL.

En el siguiente gráfico de la Figura 41 se hace una comparativa en términos de R^2 y RMSE entre los resultados obtenidos sin selección de características en el Experimento con reanálisis, para el caso de ventana móvil y 150 neuronas en la capa oculta, y los resultados medios de las simulaciones obtenidos seleccionando características previamente con el algoritmo genético. La ventaja que ofrece la selección de características para este caso con ventana móvil es menor que la que se tenía con ventana fija, ya que los resultados apenas mejoran, por lo que la ventaja a valorar será poder disponer de un conjunto de características menor para entrenar la red neuronal, consiguiendo resultados similares a los que se obtenían con el conjunto completo.

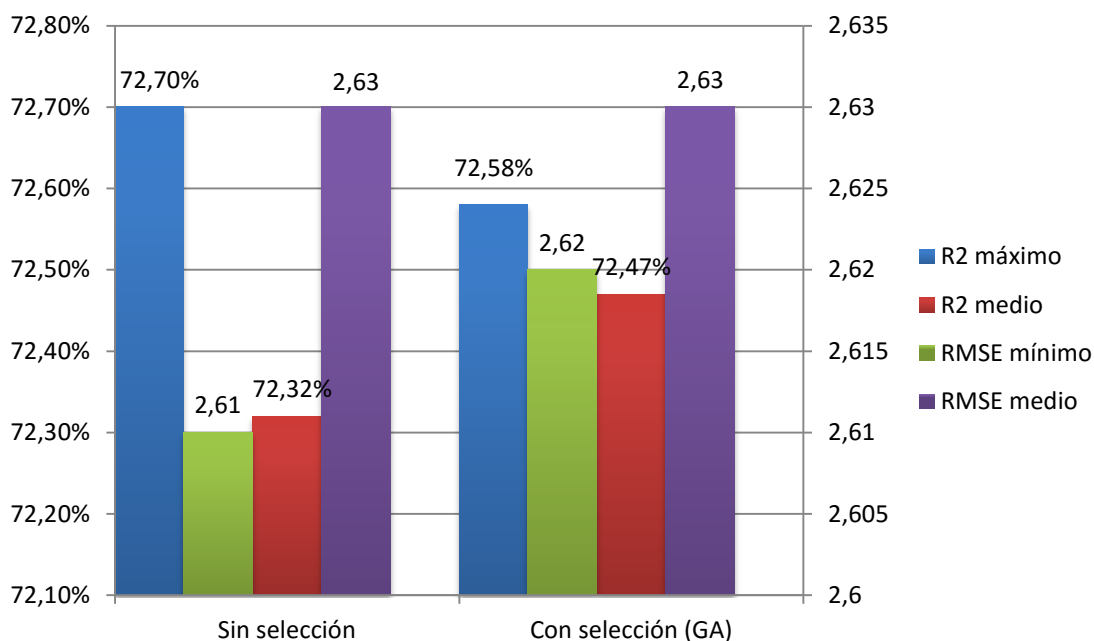


FIGURA 41. COMPARATIVA EXPERIMENTO CON REANÁLISIS Y EXPERIMENTO CON SELECCIÓN PARA VENTANA MÓVIL.

COMPARATIVA VENTANA FIJA Y VENTANA MÓVIL EXPERIMENTO 3:

El objetivo para este experimento es observar la ventaja que se obtiene al emplear algoritmos genéticos para optimización de los resultados. En este caso se aplicaba un algoritmo genético para selección de características de entrada, realizando varias simulaciones y escogiéndose distinto individuo en cada una de ellas. El resultado final a tener en cuenta en este experimento será la media de los resultados obtenidos en las 5 simulaciones, para poder tener un criterio generalizado.

El gráfico de la Figura 42 muestra una comparativa de las dos ventanas, para el caso de 150 neuronas en la capa oculta, con los resultados medios obtenidos en este Experimento con selección.




FIGURA 42. COMPARATIVA DE RESULTADOS EN EL EXPERIMENTO CON SELECCIÓN PARA VENTANA FIJA VS VENTANA MÓVIL.

A la vista de este gráfico, la selección con ventana fija consigue unos resultados finales mejores que empleando ventana móvil, aunque parte de su éxito se debe a la ventaja en rendimiento que ya tiene la ventana fija sobre la ventana móvil antes de emplear selección de características. Además, este proceso de selección consigue mejorar los resultados para ventaja fija, pero no consigue apenas mejora con ventana móvil, como se veía en la Figura 40 y la Figura 41.

Por otro lado, el mejor individuo encontrado entre las simulaciones realizadas para cada caso, y las características que lo componen, puede verse en la Tabla 35. El proceso de selección consigue

reducir el conjunto de características de entrada a la red a 21 características para ventana fija, y 30 características en el caso de ventana móvil. Ver Tabla 19 para identificar las características.

Ventana	Características del mejor individuo encontrado
Fija	[1,2,9,12,15,16,17,18,21,28,29,36,39,40,41,42,45,47,51,53,54]
Móvil	[1,2,3,6,10,12,13,14,15,17,18,21,22,25,28,29,30,31,32,36,39,40,42,43,44,47,48,50,52,54]

TABLA 35. CARACTERÍSTICAS DE LOS MEJORES INDIVIDUOS ENCONTRADOS POR EL ALGORITMO GENÉTICO PARA VENTANA FIJA Y VENTANA MÓVIL.

En esta tabla aparecen sombreadas las características comunes para todos los individuos seleccionados con cada ventana, aunque en cuanto a características comunes a todos los individuos seleccionados, independientemente de la ventana, no existe apenas similitud, coincidiendo sólo en las características en las posiciones 1, 2 y 40. Esta coincidencia en las posiciones 1 y 2 resulta lógica, ya que corresponden a los atributos de velocidad más cercanos a la ventana en la que se debía obtener la predicción, es decir, a la velocidad en las dos horas anteriores, y la característica 40 podría considerarse entonces la más relevante para este problema de predicción. Esta característica se corresponde con la componente zonal de viento a 850hPa.

Tanto las particularidades de la selección de características como la evolución de los resultados a lo largo de estos experimentos, se verán con mayor detalle posteriormente en el apartado de conclusiones.

5. CONCLUSIONES

Este Trabajo Fin de Máster propone el empleo de redes neuronales artificiales como técnica de aprendizaje automático con el objetivo de predecir extremos de viento a corto plazo. Para ello utiliza un algoritmo de entrenamiento rápido conocido como Extreme Learning Machine (ELM), midiendo el rendimiento de la red neuronal diseñada en términos de error de predicción mediante el cálculo del RMSE, y de porcentaje de ajuste de la salida de predicción con la salida deseada, mediante el cálculo del cuadrado del coeficiente de correlación de Pearson (R^2). Además, se plantea el problema de selección de características, donde entran en juego los algoritmos genéticos. A través de un algoritmo genético se buscará el subconjunto de características de entrada al modelo neuronal, en este caso a la ELM, que consigan reducir, o al menos mantener, el error de predicción.

El rendimiento del modelo propuesto ha sido probado en un parque eólico real situado en Salamanca (España), y los pasos que se han seguido para ello han sido:

- 1- Se parte de una base de datos que contiene la velocidad de viento registrada en el parque eólico de Peñarparpa de forma horaria en el periodo de noviembre de 1995 a febrero de 2013. Se dispone además de las características de reanálisis registradas para ese mismo periodo, que consisten en 48 variables meteorológicas procedentes 4 estaciones de medida cercanas al parque.
- 2- Se llevan a cabo distintas operaciones sobre los datos de partida para formar un conjunto de datos válido para entrenar y testear la red neuronal.
- 3- Se implementa una red neuronal artificial, entrenada mediante el algoritmo ELM, capaz de predecir el máximo de velocidad de viento de las 6h siguientes a partir de los datos de velocidad de viento de las 6h anteriores.
- 4- Con el objetivo de mejorar la predicción se incorporan al modelo las características de reanálisis como variables de entrada a la ELM y se vuelve a implementar la red neuronal, consiguiendo reducir el error de predicción.
- 5- Se estudia la posibilidad de encontrar un subconjunto de características de entrada a la ELM de entre todas las disponibles, que consiga mantener, o incluso reducir, el error de predicción. Para ello se ejecuta un algoritmo genético que busca la combinación de características que mejor rendimiento ofrece.
- 6- Finalmente, con todo esto se consiguen un error de predicción mínimo de 2.47 m/s.

A continuación se muestran unas tablas que recogen los mejores resultados obtenidos en los distintos experimentos realizados y el diseño de la red neuronal que lo consigue. En la Tabla 36 se

muestra la evolución de los resultados tras las distintas mejoras para el caso de emplear ventana fija, y en la Tabla 37 la evolución de los resultados para el caso de emplear ventana móvil.

Experimento	Ventana	Núm. neuronas ocultas	Error medio (RMSE medio)	% de ajuste medio (R^2 medio)
Base	Fija	50	2.71 m/s	70.72 %
Con reanálisis	Fija	150	2.55 m/s	73.96 %
Con selección	Fija	150	2.47 m/s	75.18 %

TABLA 36. RESUMEN DE RESULTADOS PARA VENTANA FIJA.

Experimento	Ventana	Núm. neuronas ocultas	Error medio (RMSE medio)	% de ajuste medio (R^2 medio)
Base	Móvil	150	2.71 m/s	70.90 %
Con reanálisis	Móvil	150	2.63 m/s	72.32 %
Con selección	Móvil	150	2.63 m/s	72.47 %

TABLA 37. RESUMEN DE RESULTADOS PARA VENTANA MÓVIL.

Los resultados muestran que este enfoque es capaz de obtener buenos resultados de predicción, que consiguen mejorarse gracias a las modificaciones propuestas. La idea inicial de organizar el conjunto de datos empleando una ventana fija de tamaño 6 consigue buenos resultados una vez se incluyen las variables de reanálisis, pero si se tienen en cuenta exclusivamente los datos de velocidad de viento de las 6h anteriores a la entrada del modelo, como es el caso del experimento base, el procesado con ventana móvil muestra mejor porcentaje de ajuste a la salida, dando a entender que, para este caso, la red requiere de un mayor conjunto de ejemplos para ajustar mejor los pesos de las conexiones neuronales.

Una vez se introducen las variables de reanálisis al modelo se consigue aportar información extra a la red, ayudando a que ésta ajuste los pesos de sus conexiones para el problema propuesto, consiguiendo minimizar el error de predicción en torno a un 6% respecto al experimento base para el caso de emplear ventana fija, que es el tipo de ventana que mejores resultados obtiene en este experimento con reanálisis. El motivo por el que la predicción mejora aun habiendo incorporado el conjunto completo de características es que éstas han sido adecuadamente seleccionadas del dataset ERA-Interim y son variables que tienen estrecha relación con la velocidad de viento, de forma que, aunque algunas contribuyan en menor medida a la predicción o incluso la empeoren, el efecto que tiene incorporarlas en conjunto a la entrada de la red es positivo.

Posteriormente se propone la selección de características empleando un algoritmo genético. Esta medida supone una mejora tanto en el caso de ventana fija, con una reducción del 3% del error, como en ventana móvil, aunque para esta última la mejora es muy pequeña, además de partir con ventaja en el caso de ventana fija ya que consiguió un error inferior con el conjunto completo de características en el experimento con reanálisis.

Atendiendo entonces al caso de ventana fija, que es el diseño que mejores resultados obtiene, cuando se lleva a cabo la selección del mejor subconjunto de características se consigue reducir el conjunto de un total de 54 características, teniendo en cuenta variables de velocidad de viento y variables de reanálisis, a 21 características, para el caso del individuo que mejor resultado ha obtenido de entre las 5 simulaciones realizadas. Esto supone tanto un ahorro en el coste de disponer del conjunto de datos de entrada para entrenar y testear el modelo, como una reducción del tiempo de ejecución del algoritmo, así como su complejidad.

Resulta lógico comprobar que en todas las simulaciones realizadas para la selección de características, las características correspondientes a las columnas 1 y 2 resulten siempre escogidas. Esto se debe a que dichas características corresponden a los datos de velocidad de viento de las 2h anteriores al periodo en el que se desea predecir el máximo, por lo que son los 2 datos de velocidad más próximos al intervalo de predicción. Por otro lado, para el caso del mejor individuo encontrado con ventana fija, las características meteorológicas dominantes frente al resto de características pueden apreciarse en la Tabla 38. Destacan la componente zonal de viento a 10 m, la componente zonal de viento a 500 hPa, y principalmente la temperatura a 850 hPa y todas las componentes a esa presión: componente zonal, componente meridional y componente vertical del viento, por lo que se deduce que las componentes de viento a una altitud de 1.457 m (850 hPa) son más relevantes en la predicción que las componentes a 5.574 m (500 hPa).

Est.1	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.2	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.3	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.4	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂

TABLA 38. CONJUNTO DE CARACTERÍSTICAS DE REANÁLISIS DEL MEJOR INDIVIDUO PARA VENTANA FIJA.

Además, teniendo en cuenta las 5 ejecuciones que se han llevado a cabo con el algoritmo genético para generalizar los resultados de selección, los mejores individuos que han sido seleccionados en estas ejecuciones coinciden en ciertas características que resultan siempre escogidas, además de las características 1 y 2, que como ya se dijo representan a las velocidades de viento de las 2h anteriores. Estas variables aparecen indicadas en la Tabla 39.

Est.1	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.2	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.3	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂
Est.4	skt	sp	u ₁₀	v ₁₀	temp ₁	up ₁	vp ₁	wp ₁	temp ₂	up ₂	vp ₂	wp ₂

TABLA 39. CONJUNTO DE CARACTERÍSTICAS COMUNES A LOS MEJORES INDIVIDUOS PARA VENTANA FIJA.

Para llevar a cabo todo este procedimiento ha sido necesario también tomar ciertas decisiones que afectaban a los resultados de este estudio. Principalmente estas decisiones se han tomado en la fase inicial, a la hora de manejar la base de datos proporcionada. Como ya se comentó al hablar de los materiales empleados, los datos de velocidad de viento estaban recogidos en un periodo horario, distinto al periodo de 6 horas en que se habían recogido los datos de reanálisis. Si en un experimento se querían tener a la par datos de viento y datos de reanálisis, como es el caso del

segundo experimento, iba a ser necesario adaptar los periodos, y para ello los datos de viento horarios iban a tener que ser agrupados en ventanas de 6 datos de velocidad de viento por fila, dando lugar así al dataset de atributos de velocidad de viento que se emplea desde el primer momento en el experimento base.

También se comentó que los datos de velocidad de viento contenían valores no válidos en el lugar donde el anemómetro no había registrado una medida de velocidad de viento, y que estaban identificados con un valor de velocidad de -99 m/s. Además, cerca de esas posiciones podían encontrarse medidas consecutivas de velocidad de viento inferiores a 0.1 m/s, que por su valor y situación posiblemente fueran medidas no válidas, por lo que en dichas posiciones se ha almacenado en su lugar un valor de -99 m/s para ser tratados como datos no válidos. Estos datos se han considerado no válidos para entrenar la red, por lo que una vez que los dataset de velocidades de viento y de reanálisis estuvieran ajustados al mismo periodo era necesario eliminar esos datos de velocidad de viento. En este punto surge la cuestión de cuántos valores de entrada a la red hacen falta para poder predecir. Es cierto que en una fila de atributos de velocidad de entrada a la red podía haber únicamente un dato no válido, y que los 5 datos restantes sirvieran para realizar la predicción, incluso 4 datos válidos podrían considerarse suficientes para poder predecir, de forma que una posibilidad sería diseñar 3 redes neuronales con 4, 5 y 6 neuronas de entrada y hacer una media de los resultados obtenidos. Para ello se comprobó la cantidad de ejemplos disponibles con 4, 5 y 6 datos válidos, pero la cantidad de ejemplos con 4 o 5 datos válidos no era suficiente como para entrenar una red neuronal, por tanto se optó por descartar todos los ejemplos que no tuvieran los 6 datos válidos y emplear únicamente éstos como dataset de atributos de velocidad de viento.

Este dataset sería posteriormente dividido en conjuntos de entrenamiento (Train) y validación (Test) en una proporción del 80-20%, respectivamente, para poder disponer de una cantidad suficiente de ejemplos para entrenar la red y reservar una cantidad menor para probar el rendimiento del modelo. Además, en el momento de pasar estos ejemplos como entrada a la función "elm", será necesario previamente normalizar las características entre $[-1, +1]$ tal como indica la recomendación, manteniendo el target en su valor original. También se realizó validación cruzada aleatoria de 10 iteraciones, entrenando y testeando la red en 10 iteraciones con distintos conjuntos de Train y Test, para asegurar la generalización de los resultados del modelo.

En cuanto a la función de activación a emplear en las neuronas de la capa oculta, se ha optado por la función sigmoïdal. Esta función es la más popular debido a sus propiedades: se trata de una función no lineal y va a aportar no linealidad en el modelo, potenciando la capacidad de las redes neuronales para aprender relaciones complejas y no lineales entre variables; su salida está acotada entre 0 y +1, por lo que la salida de activación no crecerá infinitamente según avanza el entrenamiento [50]; es fácilmente diferenciable, al ser un caso particular de la función logística, y por tanto resulta más sencilla de implementar frente a otras funciones de activación; y por último, su representación matemática con forma de "S" se asemeja al comportamiento de las neuronas, es decir, una neurona no se activa hasta recibir cierto estímulo, y en ese momento se activa gradualmente hasta llegar a un estado final de activación [51].

Otra decisión que se ha tomado a la hora de realizar el experimento con reanálisis ha sido referente a la asignación de los predictores de reanálisis al dataset de velocidades de viento. Para el caso de emplear ventana fija la asignación era inmediata puesto que los datos de velocidad de

viento se habían agrupado en ventanas de 6 datos, tomando un periodo de 6h entre ejemplos, igual al periodo en que se habían registrado las medidas de reanálisis. Sin embargo, para el caso de emplear ventana móvil, donde el desplazamiento de la ventana entre ejemplos era únicamente de una hora, se optó por asignar a cada ventana de velocidades de viento los predictores de reanálisis más cercanos a ese intervalo, como indica la Tabla 6 de la sección 4.2, de forma que existían ventanas de datos de viento que compartían los mismos datos de reanálisis. Esta asignación no es del todo cierta, ya que en cada intervalo horario podrían tenerse distintas medidas de reanálisis, pero ante la diferencia de periodos de medida se decidió constituir el dataset de entrada a la red neuronal de esta forma con la intención de asociar a cada ejemplo las medidas que más se aproximan a la realidad.

En el experimento base inicial se obtuvieron resultados ligeramente mejores con ventana móvil que con ventana fija, pero posteriormente al añadir al experimento el dataset de reanálisis se consigue mejorar considerablemente los resultados con ventana fija (-6% del error y +3.2% del porcentaje de ajuste), mientras que apenas se mejora la mitad con ventana móvil (-3% del error y +1.4% del porcentaje de ajuste). Esto puede ser debido a que los datos aportados para ventana móvil no resulten tan relevantes para el problema al haber sido asignados de la forma descrita anteriormente.

Finalmente se lleva a cabo el proceso evolutivo mediante un algoritmo genético para seleccionar las características de entrada a la red neuronal más relevantes para el problema. Con esto se consigue reducir el conjunto de características de entrada a 21 características de un total de 54 para ventana fija, y 30 características para ventana móvil, consiguiendo también una mejora de los resultados, principalmente con ventana fija, donde se reduce el error en un 3%.

En esta fase también ha sido necesario decidir ciertos parámetros de diseño del algoritmo genético:

- El tamaño de la población, que debe ser suficiente para realizar una buena búsqueda de soluciones pero no excesivo para no penalizar el tiempo de ejecución, se ha escogido de 100 individuos o cromosomas que irán evolucionando en cada generación.
- Un operador de cruce basado en dos puntos, para dar lugar a nuevos individuos, con una probabilidad de cruce del 100% para crear dos nuevos hijos en cada generación.
- Un operador de mutación con una probabilidad de ocurrencia del 5% y un porcentaje de genes a mutar del 30%. Esta probabilidad de mutación tiene como objetivo alterar parte de los genes de un individuo para así abarcar nuevas zonas del espacio de búsqueda que no se encontraban cubiertas por la población actual y evitar que la población converja a un óptimo local. No obstante, debe asignarse una probabilidad pequeña para no degenerar la población actual ni realizar la búsqueda de forma aleatoria.
- Un método de selección por torneo, para evitar que el algoritmo converja demasiado pronto, eliminando los dos peores individuos en cada generación pero no dando más ventaja a los mejores individuos encontrados.
- El número total de generaciones que se deja evolucionar al algoritmo va a depender de la velocidad a la que converge. Inicialmente se comenzó con 50.000 generaciones para ventana fija y se pudo ver en las primeras simulaciones que la mejor solución encontrada

tenía lugar entre las 13.500 y las 27.000 generaciones, por lo que se ajustó el número de generaciones máximo a 35.000, además podía controlarse la evolución del error en ese periodo y considerar que el algoritmo había convergido a una solución cuando ésta seguía siendo seleccionada durante múltiples generaciones. En el caso de ventana móvil se redujo el límite inicial a 25.000 generaciones debido a que el tiempo de ejecución del algoritmo era mayor que con ventana fija al haberse incrementado el conjunto de ejemplos de Train, y por consiguiente el tiempo de ejecución de la función de fitness. En este caso la mejor solución encontrada tenía lugar entre las 6200 y las 8700 generaciones, por lo que se ajustó el número de generaciones máximo a 10.000.

Un ejemplo de la evolución de la mejor solución encontrada (menor error) para cierta simulación a lo largo del algoritmo genético puede verse en la Figura 43 tanto para ventana fija como para ventana móvil:

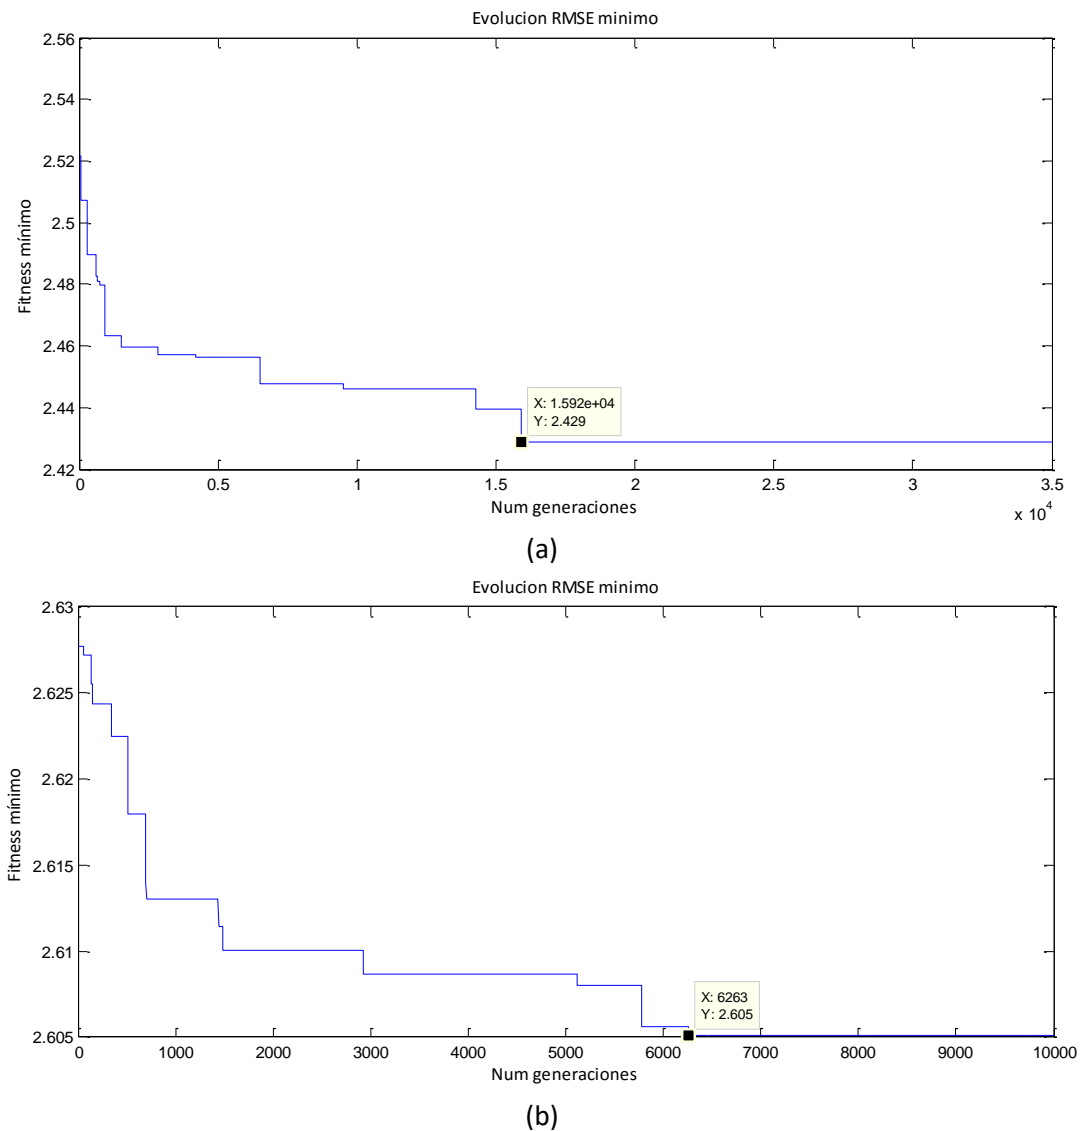


FIGURA 43. EVOLUCIÓN DEL ERROR MÍNIMO EN EL ALGORITMO GENÉTICO PARA (A) VENTANA FIJA Y (B) VENTANA MÓVIL.

Como puede verse, existe cierto error de predicción en la salida de la red neuronal diseñada, que es posible mejorar con distintas alternativas, pero no ha sido posible eliminar ni reducirlo a un valor insignificante.

Con el propósito de indagar en el motivo por el cual la red presenta este error, además de culpar a la naturaleza aleatoria del viento y su comportamiento, por lo general, más turbulento y cambiante durante el día que durante la noche, se ha realizado un análisis más detallado sobre los datos disponibles para entrenar la red.

En este análisis de los ejemplos (compuestos por el target y las características) empleados para el entrenamiento y la validación de la red neuronal diseñada, se ha encontrado que cerca del 72% de los ejemplos tratan de predecir una velocidad de viento máxima en las 6h siguientes superior a la velocidad de viento media de la 6h anteriores, es decir, en el 72% de los ejemplos el valor de target es superior a la media de sus características de entrada. Esta cifra indica que la red va a aprender que lo más probable, dada su experiencia, es que la velocidad predicha esté por encima de la velocidad media de los atributos de entrada al algoritmo, lo cual en muchos ejemplos será así pero en otros le llevará a error.

Clasificación de ejemplos válidos




FIGURA 44. CLASIFICACIÓN DE EJEMPLOS VÁLIDOS PARA EL DISEÑO DE LA RED.

Dado que, como ya se comentó, antes del entrenamiento de la red se realiza una “limpieza” del dataset de ejemplos, eliminando aquellos que tienen algún valor no válido, podría pensarse que estos datos no válidos han caído en ejemplos que, en caso de ser válidos, hubieran sido ejemplos donde el target era inferior a la media, equilibrándose así la cantidad de ejemplos iniciales de predicción por encima y por debajo de la media, pero esto no es así. Seleccionando estos ejemplos eliminados del dataset por no ser válidos para nuestro propósito, se ha comprobado que el 78% de estos ejemplos contenían en su totalidad valores no válidos, y sólo el 22% restante consistían en ejemplos donde o los atributos eran parcialmente no válidos o el target no era válido. En este 22%, si se tienen en cuenta únicamente los datos válidos, sólo el 7% serían ejemplos con un target inferior a la media de los atributos.

Clasificación de ejemplos no válidos




FIGURA 45. CLASIFICACIÓN DE EJEMPLOS NO VÁLIDOS PARA EL DISEÑO DE LA RED.

El hecho de que exista una mayoría de ejemplos con un target por encima de la media de las entradas puede venir motivado, además de por la disposición de los datos horarios en esa forma, por los casos donde el viento aumenta rápidamente. Al predecir el máximo en las 6h siguientes, si el viento está aumentando su velocidad en la ventana de predicción, al cabo de 6h puede haberse incrementado en varias unidades por encima de la media de la ventana actual. Es el caso del ejemplo representado en la Tabla 40. Mientras que si el viento aumenta suavemente o disminuye, la diferencia entre la media de las características y el target será menor.

Características de entrada						Media	Target
10.02 m/s	9.32 m/s	8.95 m/s	9.15 m/s	9.07 m/s	9.29 m/s	9.30 m/s	17.62 m/s
17.11 m/s	17.62 m/s	16.02 m/s	12.60 m/s	12.16 m/s	11.31 m/s	14.47 m/s	15.50 m/s

TABLA 40. EJEMPLO CON TARGET SUPERIOR A LA VELOCIDAD MEDIA.

Este caso se da en mayor medida que un ejemplo con un target muy inferior a la media de las características. Concretamente, en los ejemplos donde $target > v_{media}$ (72%), la diferencia entre el target y la media es superior a 3 m/s en casi el 50% de los ejemplos, mientras que en los ejemplos donde $target < v_{media}$ (28%) la diferencia es inferior a 3 m/s en más del 80% de los ejemplos.

La Figura 46 expresa de forma esquemática este análisis realizado sobre el conjunto de ejemplos disponibles mediante porcentajes aproximados.

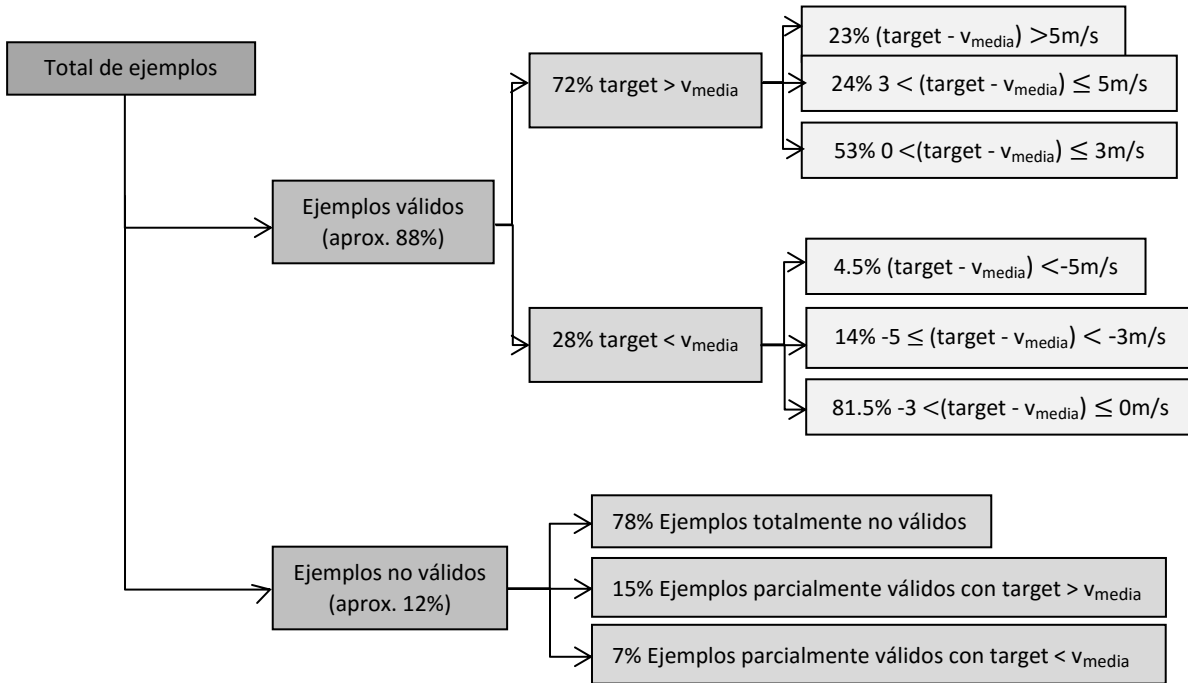


FIGURA 46. ANÁLISIS DE TARGET Y VELOCIDAD MEDIA PARA EL CONJUNTO DE EJEMPLOS.

En base a estas suposiciones sobre el aprendizaje de la red, se ha creído conveniente comprobar si el error de predicción que se produce al testear la red diseñada es debido a una predicción por encima o por debajo de la salida deseada. Como se planteaba anteriormente, este conjunto de ejemplos está enseñando a la red que existe más probabilidad en que la salida deseada esté por encima del valor medio de las entradas que por debajo, por lo que podría llevar a ésta a error dando lugar a predicciones por encima del valor deseado.

Analizando la salida de predicción de la red, se comprueba que el 6% de los errores se producen por haber predicho por encima del valor real, de los cuales el 38% son errores más significativos, de más de 2 m/s de diferencia, y el 62% de los errores son inferiores a 2 m/s.

En la Figura 47 se puede ver de forma esquemática las conclusiones sobre este análisis de errores realizado sobre el conjunto de ejemplos de test durante varias simulaciones.

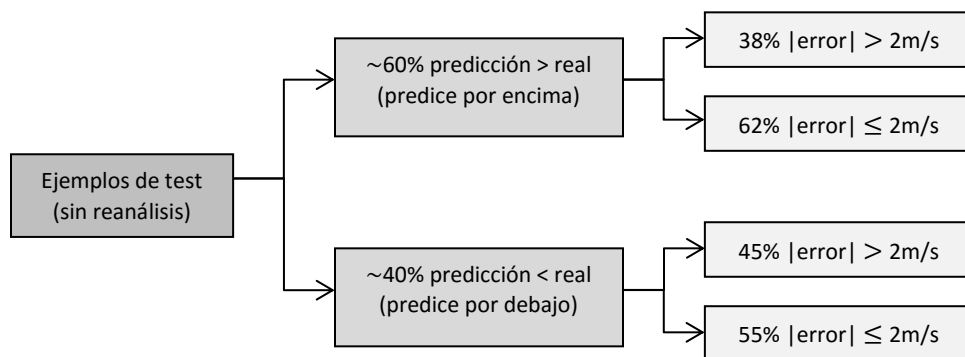


FIGURA 47. ANÁLISIS DE ERRORES PARA LA SALIDA DE PREDICCIÓN SIN REANÁLISIS.

Otro apunte que se hacía es que, vistos los resultados obtenidos en los experimentos, al incorporar los datos de reanálisis al modelo aportaban más información a la red y conseguía reducir el error de predicción. Analizando en ese caso los errores de salida de predicción se obtienen los porcentajes de la Figura 48.

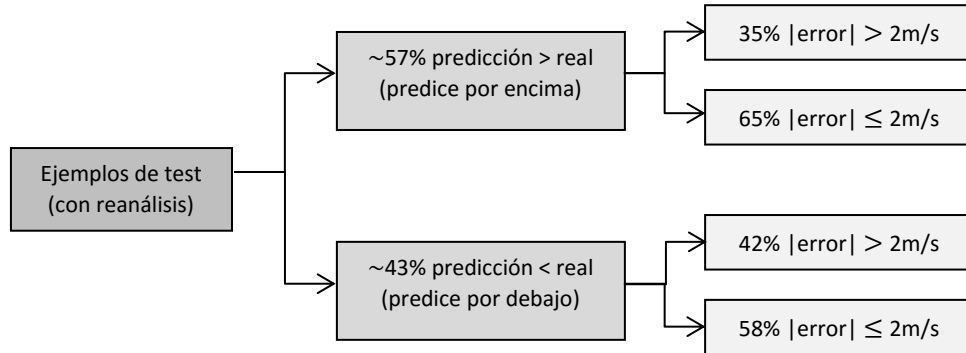


FIGURA 48. ANÁLISIS DE ERRORES PARA LA SALIDA DE PREDICCIÓN CON REANÁLISIS.

A la vista de los porcentajes, al incluir reanálisis en el modelo, parte de los errores que anteriormente eran superiores a 2 m/s disminuyen y consiguen reducirse por debajo de 2 m/s.

La Figura 49 pretende mostrar las salidas de predicción antes y después de incluir reanálisis, comparadas con la salida deseada, para un mismo conjunto de Test. En ella puede verse que, por lo general, la opción con reanálisis consigue ajustarse mejor a la predicción real, especialmente alcanzando mejor los mínimos de predicción.




FIGURA 49. COMPARATIVA DE PREDICCIÓN ANTES Y DESPUÉS DE INCLUIR REANÁLISIS.

Este ajuste a la salida real podrá mejorar, en cierta medida, si se lleva a cabo posteriormente la selección de características de entrada, tal como se demostró con el tercer experimento.

LÍNEAS FUTURAS

- Realizar el mismo estudio con distinta base de datos para comprobar el comportamiento de la red si se entrena con un reparto de ejemplos con predicción por encima y por debajo de la media más equiparada.
- Encontrar la forma de asignar los predictores de reanálisis al conjunto de atributos de velocidad para el caso de ventana móvil que no afecte a su rendimiento.
- Emplear máquinas de vectores soporte para regresión (SVMr) para predecir extremos de viento con las características seleccionadas mediante ELM+GA en este estudio.
- Llevar a cabo la selección de características mediante el algoritmo Coral Reefs Optimization (CRO) y realizar una comparativa con los resultados obtenidos con el GA.

6. PLIEGO DE CONDICIONES

En este capítulo se presentan las condiciones, tanto materiales y de equipos como de ejecución, bajo las que ha sido desarrollado este Trabajo Fin de Máster.

6.1. CONDICIONES MATERIALES Y DE EQUIPOS

HARDWARE

Por un lado, para llevar a cabo el tratamiento inicial de los datos y la implementación y ejecución de las redes neuronales diseñadas en el proyecto, así como para la redacción de esta memoria, se ha utilizado un ordenador portátil con las siguientes características:

- Procesador Intel® Core™2 Duo P7350 @ 2.00GHz 2.00GHz.
- Memoria RAM 4 GB.
- Dos unidades de disco duro de 250 GB.
- Tarjeta gráfica NVIDIA GeForce 9300M GS de 256MB.
- Periféricos: teclado (incluido en el portátil) y ratón.

Por otro lado, para ejecutar el algoritmo genético para selección de características, que tiene mayor carga computacional y consume más recursos, se ha utilizado un ordenador de sobremesa con las siguientes características:

- 4 procesadores Intel® Core™ i3 530 @ 2.93 GHz.
- Memoria RAM 4 GB.
- Disco duro de 596,17 GB.
- Tarjeta gráfica Intel® HD Graphics de 1.68 GB.
- Periféricos: teclado y ratón.

SOFTWARE

- Sistema operativo:
 - Ordenador portátil: Windows 10 Pro 64 bits.
 - Ordenador de sobremesa: Windows 7 Home Premium 64 bits.
- Software de desarrollo:
 - Ordenador portátil: MATLAB R2014a.
 - Ordenador de sobremesa: MATLAB R2014a.

- Procesador de textos:
 - Ordenador portátil: Microsoft Word 2010.
- Procesador de cálculo:
 - Ordenador portátil: Microsoft Excel 2010.

6.2. CONDICIONES DE EJECUCIÓN

Dado que el interés de este trabajo reside en poder modificar distintos parámetros de las redes neuronales (número de nodos, función de activación o conjuntos de entrenamiento y validación), así como emplear nuevas bases de datos o conjuntos de variables de entrada a la ELM para comparar cómo afectan al rendimiento del modelo, es necesario que el usuario tenga unos conocimientos mínimos de programación y conozca la implementación de estos algoritmos en Matlab, descrita en el Capítulo 2. MÉTODOS de esta memoria.

7. PRESUPUESTO

La realización de este Trabajo Fin de Grado ha supuesto unos costes cuyo presupuesto se desglosa a continuación.

❖ Coste de los materiales.

En este apartado se engloba el precio del uso de los diversos equipos empleados para desarrollar el presente trabajo, describiendo tanto el precio de la parte hardware como el de la parte software, y se resume finalmente el coste por material informático utilizado durante la realización del proyecto.

➤ Recursos hardware

EQUIPO	Total en €
<i>Portátil Acer Aspire 6930G</i>	599 €
<i>PC Acer Aspire X3900</i>	649 €
TOTAL RECURSOS HARDWARE	1.248 €

TABLA 41. COSTE DE LOS RECURSOS HARDWARE EMPLEADOS EN EL PROYECTO.

➤ Recursos software

SOFTWARE	PRECIO	AMORTIZACIÓN	Tiempo utilizado	Total en €
<i>Matlab R2014a</i>	2.000 €	1 año	8 meses	1.333,33 €
<i>Microsoft Office 2010</i>	110 €	3 años	8 meses	24,44 €
TOTAL RECURSOS SOFTWARE				1.357,77 €

TABLA 42. COSTE DE LOS RECURSOS SOFTWARE EMPLEADOS EN EL PROYECTO.

Llegados a este punto, se puede realizar el cálculo final del coste que supone el conjunto de recursos utilizados:

TOTAL DE LOS RECURSOS HARDWARE	1.248 €
TOTAL DE LOS RECURSOS SOFTWARE	1.357,77 €
TOTAL MATERIALES	2.605,77 €

TABLA 43. COSTE DE LOS RECURSOS MATERIALES EMPLEADOS EN EL PROYECTO.

El coste total de los materiales empleados asciende a **dos mil seiscientos cinco euros con setenta y siete céntimos**.

❖ **Coste de mano de obra.**

Los costes que se incluyen en este apartado se derivan del pago por la mano de obra utilizada para realizar el presente proyecto. En este tipo de costes aparecen los derivados del diseño de Ingeniería, redacción y realización del libro (mecnografía).

En el Convenio colectivo de empresas de ingeniería se establece una retribución anual para el Nivel 1 (Licenciados y titulados 2.º y 3.º ciclo universitario y Analistas) de 23.618,28€. Dado que el tiempo de ejecución ha sido de 7 meses a tiempo parcial y 1 mes a tiempo completo, el coste por realización del proyecto asciende a 10.579,02€.

REALIZACIÓN	COSTE POR HORA	Total horas	Total en €
<i>Documentación e instalación de herramientas</i>	15 €	25 horas	375 €
<i>Diseño de Ingeniería y realización del Proyecto</i>	-	-	10.579,02 €
<i>Redacción del libro</i>	10 €	180 horas	1.800 €
TOTAL MANO DE OBRA			12.754,02 €

TABLA 44. COSTE DE LA MANO DE OBRA EMPLEADA EN EL PROYECTO.

El coste total de la mano de obra asciende a **doce mil setecientos cincuenta y cuatro euros con dos céntimos**.

❖ **Presupuesto de ejecución material.**

Se calcula como la suma del coste total material y el coste total debido a la mano de obra.

COSTE TOTAL DEL MATERIAL EMPLEADO	2.605,77 €
COSTE TOTAL DE LA MANO DE OBRA	12.754,02 €
<i>PRESUPUESTO DE EJECUCIÓN MATERIAL</i>	15.359,79 €

TABLA 45. PRESUPUESTO TOTAL DE EJECUCIÓN MATERIAL.

El presupuesto de ejecución material asciende a **quince mil trescientos cincuenta y nueve euros con setenta y nueve céntimos**.

❖ **Importe de ejecución por contrata.**

Se incluyen en este apartado los gastos derivados del uso de las instalaciones donde se ha llevado a cabo el proyecto, cargas fiscales, gastos financieros, tasas administrativas y derivados de las obligaciones de control del proyecto. De igual forma se incluye el beneficio industrial. Para cubrir estos gastos se establece un recargo del 22% sobre el importe del presupuesto de ejecución material.

COSTE TOTAL DE EJECUCIÓN MATERIAL	15.359,79 €
22% DE GASTOS FINANCIEROS, BENEFICIOS, ETC.	3.379.15 €
<i>PRESUPUESTO DE EJECUCIÓN POR CONTRATA</i>	18.738,94 €

TABLA 46. PRESUPUESTO DE EJECUCIÓN POR CONTRATA.

El importe de ejecución por contrata asciende a **dieciocho mil setecientos treinta y ocho euros con noventa y cuatro céntimos**.

❖ Honorarios facultativos.

Los honorarios facultativos por la realización del proyecto se calculan de acuerdo a lo estipulado por el Colegio Oficial de Ingenieros de Telecomunicación en el apartado de tarifas de trabajos particulares y se calculan teniendo en cuenta la siguiente expresión:

$$\text{Honorarios} = 0,07 \times P \times C$$

Siendo P el presupuesto de ejecución por contrata y C es el coeficiente de reducción.

El coeficiente de reducción es distinto dependiendo de la cantidad de P:

- Para $P < 30.050,61 \text{ €} \Rightarrow C = 1$.
- Para $60.101,21 \text{ €} > P > 30.050,61 \text{ €} \Rightarrow C = 0,9$
- Para $90.151,82 \text{ €} > P > 60.101,21 \text{ €} \Rightarrow C = 0,8$

Así en el presente proyecto se tienen los siguientes importes de honorarios facultativos:

$0,07 \times 18.738,94 \text{ €} \times 1$	1.311,73 €
TOTAL HONORARIOS FACULTATIVOS	1.311,73 €

TABLA 47. TOTAL HONORARIOS FACULTATIVOS.

El importe total de los Honorarios Facultativos es de **mil trescientos once euros con setenta y tres céntimos**.

❖ Presupuesto total.

El importe del presupuesto final de este proyecto es la suma del presupuesto por contrata y los honorarios facultativos:

PRESUPUESTO DE EJECUCIÓN POR CONTRATA	18.738,94 €
HONORARIOS FACULTATIVOS	1.311,73 €
PRESUPUESTO TOTAL	20.050,67 €
21% IVA	4.210,64 €
<i>PRESUPUESTO FINAL</i>	24.261,31 €

TABLA 48. PRESUPUESTO FINAL.

El importe final del proyecto asciende a la cantidad de **VEINTICUATRO MIL DOSCIENTOS SESENTA Y UN EUROS CON TREINTA Y UN CÉNTIMOS.**

En Alcalá de Henares, a 1 de septiembre del 2016.

Fdo.: Sara Ortega Lázaro
Ingeniera de Telecomunicaciones

BIBLIOGRAFÍA

- [1] L. A. Molina Hernández, «Gestiopolis,» 18 06 2015. [En línea]. Available: <http://www.gestiopolis.com/impacto-ambiental-por-la-explotacion-de-recursos-naturales/>. [Último acceso: 21 01 2016].
- [2] «Infom Risk,» 02 05 2012. [En línea]. Available: <https://informrisk.wordpress.com/2012/05/02/importancia-energias-renovables-medio-ambiente/>. [Último acceso: 21 01 2016].
- [3] «Importancia de la energía eólica,» *Tendenzias*, 28 08 2016.
- [4] «Asociación Empresarial Eólica,» [En línea]. Available: <http://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-espana/mapa-eolico/>. [Último acceso: 28 01 2016].
- [5] A. Cano, «Huecos de tensión y generación eólica,» *Ambiontum*, 2007.
- [6] «Red Eléctrica de España,» [En línea]. Available: <http://www.ree.es/es/>. [Último acceso: 25 05 2016].
- [7] M. Martínez Ortiz, «Blog eólica y biomasa,» 05 03 2016. [En línea]. Available: <http://eolicaybiomasamaribelytere1.blogspot.com.es/>. [Último acceso: 20 05 2016].
- [8] Gamesa, « G106-2.5 MW. G114-2.5 MW. G126-2.5 MW.,» 2015.
- [9] M. Aarre Maehlum, «Energy Informative,» 23 03 2015. [En línea]. Available: <http://energyinformative.org/wind-energy-pros-and-cons/>. [Último acceso: 20 05 2016].
- [10] «Red Eléctrica de España,» [En línea]. Available: <http://www.ree.es/es/actividades/operacion-del-sistema-electrico/precio-voluntario-pequeno-consumidor-pvpc>. [Último acceso: 30 05 2016].
- [11] «Asociación Empresarial Eólica,» 15 01 2014. [En línea]. Available: <http://www.aeeolica.org/es/new/espana-es-el-primer-pais-del-mundo-en-el-que-la-eolica-se-situa-como-la-primera-fuente-de-electricidad-en-un-ano-completo/>. [Último acceso: 08 05 2016].
- [12] «Ministerio de Industria, Energía y Turismo,» 12 07 2013. [En línea]. Available: http://www.minetur.gob.es/es-es/gabineteprensa/notasprensa/2013/documents/presentacion_reforma%20el%C3%A9ctrica120713_v5.pdf.
- [13] «Asociación Empresarial Eólica,» [En línea]. Available: <http://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-espana/generacion-eolica/>. [Último acceso: 26 05 2016].


- [14] «Plan de Energías Renovables (PER) 2011-2020,» 2011.
- [15] «GWEC global wind statistics. Global Wind Energy Commission,» 2015. [En línea]. Available: http://www.gwec.net/wp-content/uploads/vip/GWEC-PRstats-2015_LR.pdf.
- [16] «GWEC global wind statistics. Global Wind Energy Commission,» 2014. [En línea]. Available: http://www.gwec.net/wp-content/uploads/2015/02/GWEC_GlobalWindStats2014_FINAL_10.2.2015.pdf.
- [17] S. Salcedo Sanz, D. Gallo Marazuela, A. Pastor Sánchez, L. Carro Calvo, A. Portilla Figueras y L. Prieto, «Offshore wind farm design with the Coral Reefs Optimization algorithm.,» *Renewable Energy*, vol. 63, pp. 109-115, 2014.
- [18] B. Fernández Parada y J. García Larrinoa, «Los vientos del cambio: energía minieólica y generación distribuida,» *Revistatope*.
- [19] S. Nistal Ruiz, «Asociación Empresarial Eólica,» 10 2010. [En línea]. Available: http://www.aeeolica.org/uploads/documents/jir2010/III_Santiago-Nistal_ELECTRIA-WIND.pdf?phpMyAdmin=nkH26XnGN7Ws3Rn1f-QjR33eVc7. [Último acceso: 11 07 2016].
- [20] «SEIA, Solar Energy Industries Association,» [En línea]. Available: <http://www.seia.org/policy/distributed-solar/net-metering>. [Último acceso: 2 06 2016].
- [21] «Energía y sociedad,» [En línea]. Available: <http://www.energiaysociedad.es/ficha/3-3-objetivos-de-produccion-con-fuentes-renovables-en-la-union-europea-y-en-espana>. [Último acceso: 12 06 2016].
- [22] «Red Eléctrica de España,» 26 07 2010. [En línea]. Available: <http://www.ree.es/es/sala-de-prensa/infografias-y-mapas/centro-de-control-de-energias-renovables-cecre-con-locucion>. [Último acceso: 20 06 2016].
- [23] «Statistical Analysis System (SAS) España,» [En línea]. Available: http://www.sas.com/en_id/insights/analytics/machine-learning.html. [Último acceso: 06 05 2016].
- [24] S. Salcedo Sanz, R. C. Deo, L. Carro Calvo y B. Saavedra Moreno, «Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms,» *Theoretical and Applied Climatology*, 2015.
- [25] J. A. Cruz y D. S. Wishart, «Applications of Machine Learning in Cancer Prediction and Prognosis,» 2007.
- [26] S. Salcedo Sanz y C. Bousoño Calzón, «A hybrid neural-genetic algorithm for the frequency assignment problem in satellite communications,» *Applied Intelligence Journal*, vol. 22, nº 3, pp. 207-218, 2005.

- [27] Á. Montero Casarejos, «Predicción de quiebras empresariales mediante inteligencia artificial,» 2016.
- [28] «Machine Learning in Marketing,» 2 07 2016. [En línea]. Available: <http://www.optimove.com/learning-center/machine-learning>. [Último acceso: 20 07 2016].
- [29] J. Bezos, «Business Insider,» 27 04 2011. [En línea]. Available: <http://www.businessinsider.com/why-i-jeff-bezos-keep-spending-billions-on-amazon-rd-2011-4>. [Último acceso: 15 07 2016].
- [30] E. G. Ortiz García, S. Salcedo Sanz, A. M. Pérez Bellido, J. Gascón Moreno, A. Portilla Figueras y L. Prieto, «Short-term wind speed prediction in wind farms based on banks of support vector machines,» *Wind Energy*, vol. 14, nº 2, pp. 193-207, 2011.
- [31] S. Salcedo Sanz, E. Ortiz García, A. M. Pérez Bellido, J. A. Portilla Figueras, L. Prieto, D. Paredes y F. Correoso, «Performance comparison of multilayer perceptrons and support vector machines in a short-term wind speed prediction problem,» *Neural Network World*, vol. 19, nº 1, pp. 37-51, 2009.
- [32] M. A. Mohandes, T. O. Halawani, S. Rehman y H. A. A., «Support vector machines for wind speed prediction,» *Renewable Energy*, vol. 29, nº 6, pp. 939-947, 2004.
- [33] S. Salcedo Sanz, A. M. Pérez Bellido, E. G. Ortiz García, A. Portilla Figueras, L. Prieto y F. Correoso, «Accurate short-term wind speed prediction by exploiting diversity in input data using banks of artificial neural networks,» *Neurocomputing*, vol. 72, pp. 1336-1341, 2009.
- [34] R. Jursa, «Variable selection for wind power prediction using particle swarm optimization,» *Proc. of the 9th Genetic and Evolutionary Computation Conference (GECCO)*, pp. 2059-2065, 2007.
- [35] R. A. Gupta, R. Kumar y A. K. Bansal, «Selection of input variables for the prediction of wind speed in wind farms based on genetic algorithms,» *Wind Eng*, vol. 35, nº 6, pp. 649-660, 2011.
- [36] S. Salcedo Sanz, A. Pastor Sánchez, A. Blanco Aguilera, L. Prieto y R. García Herrera, «Feature Selection in Wind Speed Prediction Systems based on a hybrid Coral Reefs Optimization -- Extreme Learning Machine Approach,» *Energy Conversion and Management*, vol. 87, pp. 10-18, 2014.
- [37] S. Salcedo Sanz, A. Pastor Sánchez, J. del Ser, L. Prieto y Z. W. Geem, «A Coral Reefs Optimization algorithm with Harmony Search operators for accurate wind speed prediction,» *Renewable Energy*, vol. 75, pp. 93-101, 2015.
- [38] S. Salcedo Sanz, *Apuntes Introducción a la Computación Neuronal*, 2014.
- [39] R. Flórez López y J. M. Fernández Fernández, *Las Redes Neuronales Artificiales. Fundamentos*

teóricos y aplicaciones prácticas..

- [40] C. Stergiou y D. Siganos, «Neural Networks,» [En línea]. Available: [https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html#Why use neural networks](https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html#Why_use_neural_networks). [Último acceso: 23 07 2016].
- [41] H. Guang Bin, Z. Qin Yu y S. Chee Kheong, «Extreme learning machine: Theory and applications,» *Neurocomputing*, vol. 70, pp. 489-501, 2006.
- [42] «Extreme Learning Machine,» [En línea]. Available: http://www.ntu.edu.sg/home/egbhuang/elm_codes.html#. [Último acceso: 25 02 2016].
- [43] J. Brownlee, «Machine Learning Mastery,» 21 03 2016. [En línea]. Available: <http://machinelearningmastery.com/overfitting-and-underfitting-with-machine-learning-algorithms/>. [Último acceso: 28 06 2016].
- [44] «Carnegie Mellon University,» [En línea]. Available: <https://www.cs.cmu.edu/~schneide/tut5/node42.html>. [Último acceso: 29 06 2016].
- [45] C. Darwin, El origen de las especies por medio de la selección natural, 1859.
- [46] A. Moujahid, I. Inza y P. Larrañaga, *Algoritmos genéticos*, 2008.
- [47] A. Mateos Andaluz, *Algoritmos Evolutivos y Algoritmos Genéticos*, 2005.
- [48] J. Brownlee, «Machine Learning Mastery,» 6 09 2014. [En línea]. Available: <http://machinelearningmastery.com/an-introduction-to-feature-selection/>. [Último acceso: 19 07 2016].
- [49] «ECMWF - European Center for Medium-Range Weather Forecasts,» [En línea]. Available: <http://apps.ecmwf.int/datasets/data/interim-full-daily/levtype=sfc/>.
- [50] A. Scoica, «Quora,» [En línea]. Available: <https://www.quora.com/Why-are-sigmoid-functions-such-popular-activation-functions-for-artificial-neural-networks-Could-other-nonlinear-functions-be-used-with-the-same-effectiveness>. [Último acceso: 25 08 2016].
- [51] L. Otavio Martins, «Quora,» [En línea]. Available: <https://www.quora.com/What-is-the-sigmoid-function-and-what-is-its-use-in-machine-learning-neural-networks>. [Último acceso: 25 08 2016].

Universidad de Alcalá
Escuela Politécnica Superior



ESCUELA POLITECNICA
SUPERIOR



Universidad
de Alcalá