



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA
SUPERIOR INGENIEROS
INDUSTRIALES VALENCIA

TRABAJO DE FIN DE GRADO EN INGENIERÍA DE LA ENERGÍA

**MODELIZACIÓN Y PREDICCIÓN DE LA
ENERGÍA ELÉCTRICA PRODUCIDA EN UN
AEROGENERADOR UTILIZANDO MODELOS
ESTOCÁSTICOS TEMPORALES A PARTIR DE
SERIES DE VIENTO**

AUTOR: ALEXANDER MARCO CARPENA

TUTOR: JUAN CARLOS GARCÍA DÍAZ

Curso académico: 2016-17

AGRADECIMIENTOS

Es curioso que las primeras palabras en leerse sean de las últimas en escribirse, siendo estas las más difíciles por el cambio de chip que supone tras haber redactado el resto del trabajo, pero a su vez, las más simpáticas de escribir por lo que expresan.

Así, quiero dar las gracias en primer lugar a Juan Carlos García Díaz, por darme la oportunidad de realizar este trabajo bajo su tutela y haberme guiado y ayudado durante todo el proceso, permitiéndome hacer hincapié en un área de la ciencia que me parece muy interesante y me apasiona, en el cual estoy seguro que seguiré aprendiendo en un futuro.

A mis amigos en general y a los que han estado siempre ahí, ayudándome en los momentos difíciles que han surgido en todo este tiempo, por escucharme, aconsejarme y siempre sacarme una sonrisa cuando más se necesitaba aunque fuera a cientos de kilómetros de distancia.

Pero el agradecimiento en mayúsculas debo dárselo a mi familia, por haberme dado todo su apoyo incondicional, ánimos y consejos. Y muy especialmente a mis padres, por haberme criado con tanto cariño y haber dedicado a la formación y educación de sus hijos mil veces más tiempo y recursos que los que han dedicado a sí mismos. Muchísimas gracias y este trabajo es tan vuestro como mío.

RESUMEN

El desarrollo de las energías renovables, y como consecuencia, la alta penetración eólica en los sistemas eléctricos, ha hecho necesario el uso de herramientas de predicción para realizar la correcta gestión por parte del operador del sistema eléctrico o por los agentes que regulan uno o varios parques eólicos.

En este trabajo de fin de grado se comparan varios métodos de cálculo de la predicción de la potencia eléctrica generada por un aerogenerador para horizontes a muy corto plazo. Para ello, se estudian diferentes series temporales de las variables más significativas que afectan a la producción de energía eólica y se proponen diferentes modelos de predicción estadísticos ARIMA.

Los modelos ARIMA combinan las ventajas de los modelos de Regresión Local Ponderada y de Medias Móviles para adecuarse a la complejidad de la predicción no lineal en cada momento. Una vez elegido el modelo para cada variable, se valida y se realiza la predicción.

Las predicciones obtenidas son, a su vez, los datos necesarios para la parte final del trabajo, donde se contrastan métodos directos e indirectos de predicción de potencia. Estos métodos están basados en el modelado directo de los datos históricos de potencia frente a los modelos obtenidos a partir de las predicciones de las variables relacionadas, siendo el objetivo del trabajo determinar si existen diferencias significativas entre ambos métodos.

Para el desarrollo del trabajo ha sido necesario utilizar programas estadísticos tales como “*Statgraphics*” o el programa de código libre “*R*”, teniendo que desarrollar funciones propias para adaptar los datos y obtener datos intermedios.

PALABRAS CLAVE

Series temporales; ARIMA; predicción; energía eólica; *Statgraphics*; R; Box-Jenkins

ABSTRACT

The development of renewable energies, and consequently the high wind penetration in the electrical systems, has made it necessary to use prediction tools to carry out the correct management by the electrical system operator or by the agents that regulate one or several wind farms.

In this end-of-degree project, several methods of calculating the forecast of the electrical power generated by a wind turbine for very short-term horizons are compared. To do this, we study different time series of the most significant variables that affect wind energy production and propose different ARIMA statistical prediction models.

The ARIMA models combine the advantages of the Locally Weighted Regression and Moving Average models to fit the complexity of non-linear prediction at any given time. Once the model is chosen for each variable, it is validated and the prediction is made.

The predictions obtained are, in turn, the necessary data for the final part of the work, which contrasts direct and indirect methods of power prediction. These methods are based on the direct modelling of the historical data of power versus the models obtained from the predictions of the related variables, being the objective of the work to determine if there are significant differences between both methods.

For the development of the work, it has been necessary to use statistical programs such as "Statgraphics" or the free code program "R", having to develop its own functions to adapt the data and obtain intermediate data.

KEYWORDS

Time series; ARIMA; forecast; wind power; *Statgraphics*; R; Box-Jenkins

CONTENIDO

CONTENIDO	vii
ÍNDICE DE ILUSTRACIONES	ix
ÍNDICE DE TABLAS.....	xi
1. INTRODUCCIÓN	1
1.1 Objetivos del trabajo	1
1.2 Estructura del trabajo	1
1.3 Descripción de un aerogenerador	2
1.4 Situación actual de las energías renovables variables (VRE).....	4
1.5 La energía eólica en el sistema eléctrico español.....	5
1.6 Necesidad de predicción de energía eólica	6
2. ESTADO DEL ARTE EN PREDICCIÓN DE ENERGÍA EÓLICA	7
2.1 Horizonte de tiempo.....	7
2.2 Escala espacial.....	7
2.3 Modelos estadísticos de series temporales	8
2.4 Modelos físicos.....	8
2.5 Modelar velocidad de viento o potencia eólica	9
2.6 Incertidumbre en la predicción	9
2.7 Sipleólico	9
3. PRESENTACIÓN Y DEPURACIÓN DE DATOS	14
4. SERIE TEMPORAL DE VELOCIDADES DE VIENTO	16
4.1 Distribuciones de probabilidad	16
4.1.1 Distribución de Weibull.....	16
4.1.2 Distribución de Rayleigh.....	17
4.1.3 Distribución de Gumbel.....	18
4.2 Análisis descriptivo.....	20
4.3 Estimación, diagnóstico y validación de modelos tentativos.....	22
4.3.1 ARIMA (0, 1, 2)	22
4.3.2 ARIMA (2, 1, 2)	25
4.3.3 ARIMA (1, 0, 1)	26
4.3.4 Comparación de modelos	29
4.4 Predicción	29

5.	SERIE TEMPORAL DE TEMPERATURA.....	32
5.1	Análisis descriptivo.....	32
5.2	Estimación, diagnóstico y validación de modelos tentativos.....	34
5.2.1	ARIMA (1, 1, 1)	34
5.2.2	ARIMA (2, 1, 0)	35
5.2.3	Comparación de modelos	36
5.3	Predicción	37
5.4	Densidad del aire.....	37
6.	ESTIMACIÓN DE LA POTENCIA ELÉCTRICA.....	40
6.1	Metodología.....	40
6.2	Predicción de la serie temporal de potencia.....	40
6.2.1	Análisis descriptivo	40
6.2.2	ARIMA (1, 0, 1)	42
6.2.3	ARIMA (0, 1, 2)	43
6.2.4	ARIMA (0, 1, 1)	44
6.2.5	Comparación de modelos	45
6.2.6	Previsión	45
6.3	Predicción a través de la curva de potencia.....	46
6.4	Cálculo de la potencia teórica	49
6.5	Curvas de aerogeneradores comerciales	52
6.6	Comparación de métodos.....	56
7.	CONCLUSIONES.....	57
8.	PRESUPESTO.....	58
9.	BIBLIOGRAFÍA.....	60

ÍNDICE DE ILUSTRACIONES

Figura 1: Componentes de un aerogenerador	2
Figura 2: Participación de las VRE.....	4
Figura 3: Capacidad eólica acumulada Dic 2016	5
Figura 4: Evolución de la potencia eólica año a año en España	5
Figura 5: Esquema de funcionamiento de Sipleólico.....	10
Figura 6: Resumen distribución Weibull.....	17
Figura 7: Resumen distribución Rayleigh	18
Figura 8: Resumen distribución Gumbel	19
Figura 9: Serie temporal de la velocidad del viento	20
Figura 10: STL de la velocidad del viento	20
Figura 11: ACF y PACF de velocidad de viento	21
Figura 12: Análisis de la transformación de la velocidad del viento	21
Figura 13: Correlogramas ARIMA (0,1,2).....	24
Figura 14: Análisis de la distribución normal del ARIMA (0,1,2)	24
Figura 15: Periodograma ARIMA (0,1,2).....	25
Figura 16: Periodograma ARIMA (2,1,2).....	26
Figura 17: Correlogramas ARIMA (1,0,1).....	27
Figura 18: Análisis de la distribución normal del ARIMA (1,0,1)	28
Figura 19: Periodograma acumulado velocidad de viento ARIMA (1,0,1)	28
Figura 20: Predicción ARIMA (0,1,2).....	31
Figura 21: Serie temporal de la temperatura	32
Figura 22: Correlogramas de la temperatura	33
Figura 23: Análisis de la transformación de la serie de temperatura	33
Figura 24: Gráfico de probabilidad normal del ARIMA(1,1,1)	34
Figura 25: Gráfico de dispersión del ARIMA (1,1,1)	34
Figura 26: Periodograma acumulado de temperatura del ARIMA (1,1,1)	35
Figura 27: Gráfico de probabilidad normal del ARIMA(2,1,0).....	36
Figura 28: Gráfico de dispersión del ARIMA (2,1,0)	36
Figura 29: Periodograma acumulado de temperatura del ARIMA (2,1,0)	36

Figura 30: Predicción de temperatura ARIMA (1,1,1)	37
Figura 31: Serie temporal de la presión a 80 m de altura	38
Figura 32: Serie temporal de la densidad del aire a 80 m de altura	39
Figura 33: Predicción de densidad del aire a 80 m de altura	39
Figura 34: Serie temporal de la potencia eléctrica generada	40
Figura 35: Correlogramas de Potencia	41
Figura 36: Análisis de la distribución normal de potencia del ARIMA (1,0,1)	42
Figura 37: Periodograma acumulado de potencia ARIMA (1,0,1).....	43
Figura 38: Análisis de la distribución normal de potencia del ARIMA (0,1,1)	44
Figura 39: Periodograma acumulado de potencia ARIMA (0,1,1).....	45
Figura 40: Predicción de potencia del ARIMA (0,1,1).....	46
Figura 41: Relación entre variables	47
Figura 42: Correlación de potencia y velocidad	47
Figura 43: Regresión de la curva de potencia-velocidad.....	48
Figura 44: Coeficiente de potencia.....	50
Figura 45: Curva del coeficiente de potencia completa	51
Figura 46: Curvas de Potencia para cada aerogenerador	52
Figura 47: Catálogo de aerogeneradores Gamesa	53
Figura 48: Curva de Potencia Gamesa G80-2.0 MW	54
Figura 49: Curva de Potencia Gamesa G90-2.0 MW	55

ÍNDICE DE TABLAS

Tabla 1: Datos de series temporales	15
Tabla 2: Resumen de Weibull	16
Tabla 3: Resumen de Rayleigh.....	17
Tabla 4: Resumen de Gumbel.....	19
Tabla 5: Comparación de distribuciones	19
Tabla 8: Resumen de modelo de velocidad de viento ARIMA (2,1,2)	26
Tabla 9: Resumen de modelo de velocidad de viento ARIMA (1,0,1)	27
Tabla 10: Comparación de modelos para la velocidad de viento	29
Tabla 11: Predicción del viento en m/s	30
Tabla 12: Resumen de modelo de temperatura ARIMA (1,1,1)	34
Tabla 13: Resumen de modelo de temperatura ARIMA (2,1,0)	35
Tabla 14: Comparación de modelos para la temperatura	36
Tabla 15: Comparación de modelos para la potencia	41
Tabla 16: Resumen de modelo de potencia ARIMA (1,0,1)	42
Tabla 17: Resumen de modelo de potencia ARIMA (0,1,2)	43
Tabla 18: Resumen de modelo de potencia ARIMA (0,1,1)	44
Tabla 19: Comparación de modelos ARIMA para la potencia.....	45
Tabla 20: Predicción de potencia en kW a partir del modelo ARIMA (0,1,1).....	46
Tabla 21: Correlación entre variables.....	47
Tabla 22: Predicción de velocidad de viento en m/s.....	49
Tabla 23: Predicción de potencia en kW a partir de la curva de potencia.....	49
Tabla 24: Predicción de potencia teórica	51
Tabla 25: Pronóstico Potencia Gamesa G80-2.0 MW	54
Tabla 26: Pronóstico Potencia Gamesa G90-2.0 MW	55
Tabla 27: Resumen de pronósticos de potencia	56
Tabla 28: RMSE pronósticos de potencia	56
Tabla 29: Presupuesto total.....	59

1. INTRODUCCIÓN

1.1 Objetivos del trabajo

El propósito final de este trabajo es la modelización y predicción a muy corto plazo de la energía eléctrica vertida a la red de distribución generada por un parque eólico, considerando como variables principales los datos históricos de un aerogenerador situado en la misma localización: velocidad de viento, temperatura y potencia eléctrica.

En pos de este objetivo, se ajustarán diferentes modelos distinguiendo si realizan la predicción de forma directa (mediante los datos históricos de potencia eléctrica) o indirectamente (cómo resultado de la combinación de las demás variables). Todos estos modelos se desarrollarán mediante modelos temporales estocásticos ARIMA a través del programa estadístico *Statgraphics* y el software libre *R*.

Una vez ajustados los diferentes modelos, se estimará la potencia generada por un aerogenerador comercial y se compararán todos entre sí para determinar si existen diferencias significativas y poder cuantificarlas.

1.2 Estructura del trabajo

En el desarrollo de este trabajo se presenta de forma breve una primera introducción donde se da a conocer el funcionamiento de un aerogenerador y el estado actual del sector eólico a nivel mundial y en particular en el caso de España. Además, se aborda levemente las diferentes líneas de trabajo existentes y sus peculiaridades en el ámbito de la creación de modelos predictivos.

Seguidamente, se introducen los datos y el proceso de depuración de los mismos, los cuales son la base indispensable para el progreso del trabajo. En este apartado se eliminan datos nulos o en blanco, así como errores provenientes de los aparatos de medición.

A continuación se dedica un apartado al estudio de los datos y la distribución estadística que presenta, siendo la intención de la sección comparar y elegir la distribución que mejor se adapta a los datos reales.

A partir de este punto (apartados 4 y 5) se entra en el propósito principal del trabajo, dedicándose varios apartados al estudio de las variables recogidas. Así pues, se buscan de entre varios modelos de predicción ARIMA, aquel que cumpla con los parámetros impuestos por la metodología Box-Jenkins y que sea el que presente menor error de predicción. Este proceso se realiza para las variables de velocidad de viento y temperatura, con el objetivo de obtener un pronóstico a muy corto plazo (entre una y doce horas) que será la base para el cálculo de la energía eléctrica.

Finalmente, y debido a la ausencia de los datos reales de diseño del aerogenerador de medida, se calculan y comparan tres maneras diferentes de obtener una predicción de energía eléctrica. En estos puntos, la finalidad es comparar las tres predicciones y determinar las diferencias entre los resultados y sus respectivas causas.

1.3 Descripción de un aerogenerador

Un aerogenerador consiste en una turbina eólica que convierte la energía cinética del viento en trabajo sobre un eje giratorio y un sistema de generación, el cual está compuesto por cierto número de componentes auxiliares para un adecuado funcionamiento, que convierte esta potencia en electricidad.

El funcionamiento de un aerogenerador puede explicarse en función de las siguientes fases:

- **Orientación automática:** El aerogenerador se orienta automáticamente para aprovechar al máximo la energía cinética del viento, a partir de los datos registrados por la veleta y el anemómetro que incorpora en la parte superior. La *nacelle* gira sobre una corona situada al final de la torre.
- **Giro de las palas:** El viento hace girar las palas, que comienzan a moverse con velocidades de unos 3,5 m/s y proporcionan la máxima potencia en torno a los 11 m/s. Con vientos muy fuertes (25 m/s) las palas se colocan en bandera (posición paralela a la dirección del viento) y el aerogenerador se frena para evitar tensiones excesivas.
- **Multiplicación:** El rotor (conjunto de tres palas engarzadas en el buje) hace girar un eje lento conectado a una multiplicadora que eleva la velocidad de giro desde unas 13 a 1500 revoluciones por minuto.
- **Generación:** La multiplicadora, a través del eje rápido, transfiere su energía al generador acoplado, que produce electricidad.
- **Evacuación:** La energía generada es conducida por el interior de la torre hasta la base y, desde allí, por líneas subterráneas hasta la subestación, donde se eleva su tensión para inyectarla a la red eléctrica y distribuirla a los puntos de consumo.
- **Monitorización:** Todas las funciones críticas del aerogenerador están monitorizadas y se supervisan desde la subestación y el centro de control, para detectar y resolver cualquier incidencia.




Figura 1: Componentes de un aerogenerador

Fuente: Catálogo Gamesa G90-2.0 MW

Los componentes representados en la figura 1 se describen a continuación:

- **Rotor:** Está compuesto por las palas y el buje. El sistema de tres palas es el encargado de captar la energía cinética del viento y es el buje el encargado de transmitir la energía captada al eje principal.
- **Sistema cambio de paso:** El sistema cambio de paso es el encargado de controlar la potencia mediante el ajuste del ángulo de ataque de las palas al viento.
- **Tren de potencia:** El tren de potencia está formado por el eje principal, frenos, multiplicadora, la transmisión al eje de alta velocidad (acoplamiento multiplicadora/generador), el freno mecánico y el sistema de mantenimiento predictivo (sistema de multiprocesamiento simétrico SPM para monitoreo de vibraciones). Es el responsable de transmitir el giro del buje hasta la entrada del eje del generador multiplicando la frecuencia de giro.
- **Sistema de orientación:** Sistema que orienta la góndola o *nacelle* en la dirección del viento para conseguir un máximo aprovechamiento del mismo, o para ofrecer la mínima resistencia al paso del mismo si fuera preciso.
- **Sistema hidráulico:** Alimenta al sistema de freno mecánico, al sistema de regulación del paso y al sistema de orientación entre otros.
- **Generador:** Es el dispositivo que genera corriente eléctrica inducida en los bobinados del mismo, producida por el giro del eje del generador.
- **Transformador:** La tensión de salida del generador es generalmente baja para realizar recorridos de largas distancias, por tanto, se eleva la tensión en los transformadores para minimizar pérdidas en los cables.
- **Sistema de control:** La unidad de control y potencia se encarga de controlar todas las funciones críticas del aerogenerador con el fin de optimizar el funcionamiento del aerogenerador según sea la velocidad del viento en cada momento.
- **Sensores:** Se emplean para medir temperatura, dirección y velocidad de viento así como otros parámetros que pueden aparecer dentro de la góndola, por lo que apoyan el control de la turbina y su monitoreo. En estos sensores se incluyen el anemómetro sónico y las veletas situadas en la góndola del aerogenerador.
- **Góndola:** Es un componente estructural de la parte alta de la torre que contiene todos los componentes eléctricos y mecánicos del aerogenerador.
- **Carcasa:** Cubierta que confina dentro de un espacio cerrado los componentes eléctricos y mecánicos.
- **Torre y cimentaciones:** La torre eleva la góndola hasta el punto de captación de energía eólica y ésta es anclada al terreno mediante las virolas incrustadas dentro de cimentaciones de diseño variable, según las condiciones geotécnicas del terreno.

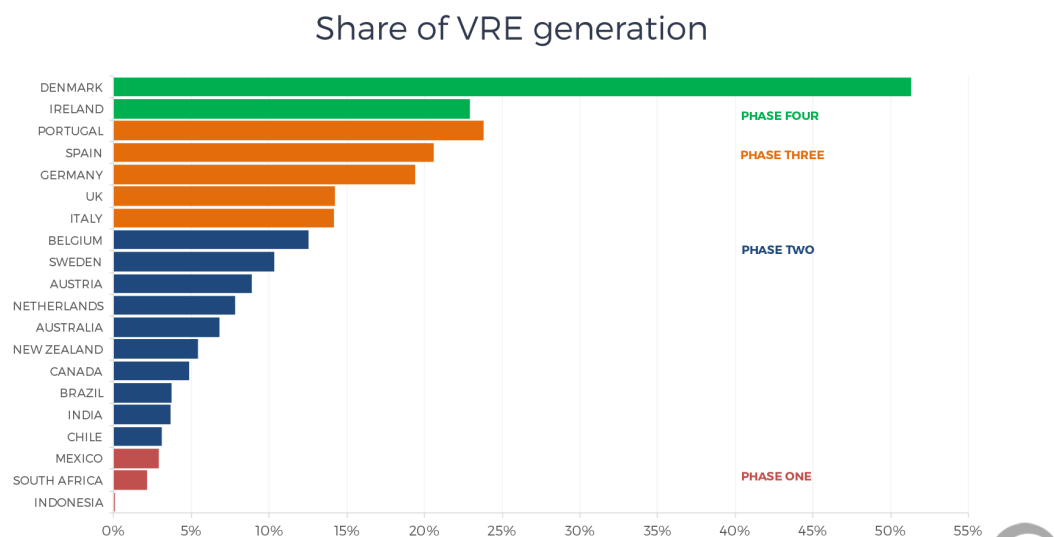
1.4 Situación actual de las energías renovables variables (VRE)

La fuerte dependencia energética, la presión social y la toma de conciencia por parte de los gobiernos en la lucha contra el cambio climático, han dado lugar a diferentes marcos regulatorios en pos de reducir los niveles actuales de emisión de CO_2 .

En vista a este objetivo, se han desarrollado mapas de ruta por la IEA (International Energy Agency) para identificar las tecnologías más importantes, entre las que destacan las energías renovables, para lograr la reducción de emisiones a la mitad en 2050.

En muchos países, gracias a la política de apoyo y al dramático descenso del coste de tecnología, la energía eólica y solar fotovoltaica ha crecido rápidamente, y al final del 2015, estas tecnologías comúnmente llamadas energías renovables variables (VRE), han alcanzado una participación anual importante en la generación de electricidad en diez países de la OCDE.

En Dinamarca, la participación de las VRE en la generación de electricidad ha aumentado hasta estar en torno al 50%, y otros países como Irlanda, Alemania y España, se encuentra en torno al 20%, en todos los casos sin comprometer la fiabilidad del suministro de electricidad.



Getting Wind and Solar onto the Grid



Figura 2: Participación de las VRE

Fuente: IEA/IRENA Global Renewable Energy Policies and Measures Database © OECD/IEA and IRENA (2015): Energy Policies of IEA Countries

Sin embargo, todavía queda mucho por hacer para estar seguro de que se cumplen los objetivos. Se requiere aún de ambientes reguladores predecibles y de apoyo, así como diseños de mercado apropiados donde sea más fácil integrar niveles más altos de energía renovable variable a la red.

1.5 La energía eólica en el sistema eléctrico español

En 2016, el 40,8% de la energía eléctrica demandada en España fue cubierto por energía renovable. Este comportamiento se explica debido a la fuerte contribución de las renovables, un sector en el cual España es uno de los líderes mundiales de los últimos 15 años, posicionándose como quinto país con más capacidad de potencia eólica instalada por detrás de China, Estados Unidos, Alemania e India.

Dentro de las renovables, la energía eólica en España supone el 22,7% del mix energético con una potencia total instalada de 23.074 MW.




Figura 3: Capacidad eólica acumulada Dic 2016
Fuente: (GWEC, 2017)

Evolución de la potencia eólica instalada año a año en España (en MW)




Figura 4: Evolución de la potencia eólica año a año en España

Fuente: (AEE, 2017)

A pesar de esto, en la política de electricidad renovable en España existen complejidades particulares relacionadas con los roles y responsabilidades en la autorización de la generación de energía renovable y en la gestión de los flujos financieros relacionados con las subvenciones a las energías renovables. Esto ha inducido un parón drástico en la potencia anual instalada desde el 2012, habiendo dispuesto en el año 2016 un total de 49 MW.

España también está a la vanguardia internacional en el desarrollo de las herramientas de operación del sistema, necesarias para integrar con seguridad una alta proporción de generación renovable variable. En este campo, España dispone de la herramienta "Sipreólico" creada por la Universidad Carlos III, la cual usa modelos estadísticos adaptativos no paramétricos y usa nueve diferentes modelos dependiendo de la disponibilidad de los datos.

1.6 Necesidad de predicción de energía eólica

La penetración global a gran escala de la energía eólica está vinculada a significantes desafíos debido a la inestable e intermitente naturaleza del viento. Una predicción a corto plazo de alta calidad de la velocidad del viento es fundamental para garantizar operaciones fiables y seguras del sistema eléctrico.

Uno de los mayores problemas de la energía eólica, en comparación con la energía eléctrica convencional, es la dependencia con la inestabilidad del viento, ya que solo se produce energía cuando sopla el viento, el cual puede ser muy variable incluso en el corto plazo. Este comportamiento ocurre en todas las escalas de tiempo, pero en dos de ellos son realmente importantes. El primero es en el control de las turbinas (de milisegundos a segundos), y el otro es importante para la integración de la energía eólica en la red eléctrica, cuyo tiempo está determinado por la red (de minutos a semanas).

Así pues, una buena predicción es necesaria para optimizar la planificación de la generación de las centrales convencionales dentro del sistema eléctrico, pudiendo dar órdenes a las centrales de respuesta rápida en un horizonte temporal entre 3-10 horas antes.

Desde el punto de vista del operador eléctrico, la predicción ayuda a garantizar la calidad y la seguridad del suministro eléctrico. Un correcto funcionamiento del sistema no solo debe cubrir la demanda, sino que también debe dar respuesta inmediata a problemas que puedan surgir, garantizando el suministro y respetando las restricciones técnicas que pueda presentar la red.

Además, la predicción de la energía eólica también es importante desde la perspectiva económica en el mercado para usuarios finales, sirviendo como herramienta para maximizar la rentabilidad mediante la toma de decisiones que maximicen los beneficios de una actividad. Esto hace que se reduzcan los costes de operación del sistema originados por la reducción de reserva necesaria, y por otro lado, la reducción de posibles penalizaciones económicas debido a los desvíos con los compromisos de generación.

Adicionalmente, en una escala de tiempo mayor, la predicción resulta interesante para planificar el mantenimiento a largo plazo de componentes de la central (turbina o líneas de transmisión). Sin embargo, la precisión de las predicciones meteorológicas disminuye con fuerza mirando con 5-7 días de antelación, y estas aplicaciones solo están empezando a aparecer.

2. ESTADO DEL ARTE EN PREDICCIÓN DE ENERGÍA EÓLICA

En general, los modelos pueden ser clasificados atendiendo a si usan o no predicciones meteorológicas (*Numerical Weather Prediction* o NWP). El uso de modelos que utilizan NWP vale la pena dependiendo del horizonte temporal que se esté tratando de predecir. Así pues, típicamente los modelos de predicción que usan NWP superan los enfoques de series temporales después de aproximadamente 3-6 horas, por lo que suele ser el enfoque más empleado.

Existen principalmente dos líneas de pensamiento respecto a la predicción de corto plazo, el enfoque físico y el estadístico, aunque últimamente han aparecido los modelos mixtos, los cuales combinan ambos enfoques para obtener pronósticos mejores.

Así, nos encontramos con que habitualmente para la obtención de predicciones de energía eólica a corto plazo entran en juego dos sistemas, el modelo de predicción de potencia a partir de las previsiones meteorológicas, y el propio modelo atmosférico de previsión meteorológica.

2.1 Horizonte de tiempo

El horizonte de predicción es el periodo de tiempo que determina el momento futuro para el que realizamos las predicciones. Los horizontes temporales se pueden clasificar como de muy corto plazo, de corto plazo y medio o largo plazo, aunque no existe unanimidad a las fronteras que separan las distintas clasificaciones.

La predicción a muy corto plazo, hasta 4-9 horas de horizonte, tiene como objetivo la mejora de la seguridad dinámica de la red y la gestión de la regulación secundaria, y resulta muy útil para el control del propio parque eólico.

Las predicciones a corto plazo, que abarcan horizontes hasta las 48 o 72 horas, son las que tienen mayor aplicación en la determinación de necesidades de generación para los mercados diarios e intradiarios.

En las predicciones a medio y largo plazo, los horizontes pueden variar entre varios días e incluso meses. Cuanto mayor sea el horizonte, mayores son los errores de predicción, resultando a día de hoy difícil realizar predicciones fiables. Estos pronósticos tienen interés en la selección de emplazamientos para ubicar parques eólicos.

2.2 Escala espacial

Los modelos de previsión meteorológica se basan en la resolución de las ecuaciones físicas que describen el estado de la atmósfera, aplicadas a una serie de puntos de una malla o rejilla tridimensional. El tamaño de esta rejilla es lo que se conoce como escala espacial y permite diferenciar entre modelos de macro-escala, modelos meso-escalares, y modelos de micro-escala.

El tamaño de la escala espacial está relacionada con el tamaño de la zona y la resolución con que se realiza la predicción.

Los modelos atmosféricos de macro-escala abarcan toda la superficie terrestre y tienen su malla definida en coordenadas esféricas. Estos modelos utilizan una aproximación hidrostática, es decir, suponen despreciables los movimientos verticales de las masas de aire, y por tanto no se tiene en cuenta la posible evolución vertical de la atmósfera.

Los modelos de macro-escala no globales son una adaptación de los modelos globales, donde se usan simplificaciones similares pero limitando el área de estudio a una región de interés. Estos modelos están acotados a una región específica, con lo que con la misma potencia de cálculo pueden tener una resolución mayor que los modelos globales.

Los modelos meso-escalares nacen como un intento de aumentar la resolución de los anteriores. Muchos de estos toman como condiciones de bordes los datos dados por los modelos macro-escalares. Así pues, considerando la topografía de la zona y teniendo en cuenta los movimientos verticales del aire, determinan un nuevo set de datos con una resolución bastante mejor para zonas delimitadas.

Por último, existen los modelos micro-escalares, los cuales pueden llegar a tener resolución de tan solo unos metros.

2.3 Modelos estadísticos de series temporales

Un modelo de predicción basado en series temporales trata de extrapolar los valores futuros que tomará una variable mediante el análisis del comportamiento pasado de dicha variable u otras explicativas.

En este grupo se encuentran los modelos ARIMA o Box-Jenkins¹ que se utilizan en este trabajo, los cuales proporcionan resultados razonablemente buenos para horizontes temporales hasta 6 horas.

Otras alternativas al modelo clásico de serie temporal vienen dadas por las redes neuronales, las cuales otorgan gran flexibilidad para solucionar diferentes tipos de problemas, aunque tienen como inconvenientes que se presentan como una caja negra, es decir, son difíciles de entender.

2.4 Modelos físicos

Los modelos físicos se basan en el modelado físico del emplazamiento donde se sitúa el parque eólico. A partir de la orografía del terreno y las predicciones meteorológicas globales o regionales, se hace una adaptación al emplazamiento en concreto usando un modelo meso-escalar o micro-escalar, tratando de predecir para cada turbina el viento que incidirá en cada una de ellas.

¹ Metodología aplicada a modelos autorregresivos de media móvil ARMA o a los modelos autorregresivos integrados de media móvil ARIMA para encontrar el mejor ajuste de predicción de una serie temporal.

Posteriormente se transforma la velocidad de viento estimada en potencia mediante el uso de la curva de potencia de cada aerogenerador.

Una de las ventajas de los modelos físicos es que para su implementación no se necesitan datos históricos, a menos que se le añada un módulo estadístico para corregir sesgos de escala. De hecho, la mayoría de los modelos físicos incorporan módulos estadísticos de mayor o menor complejidad para considerar efectos que no se tienen en cuenta y realizar correcciones, por lo que se podrían considerar modelos híbridos o mixtos.

2.5 Modelar velocidad de viento o potencia eólica

Existen varias formas de obtener un pronóstico de potencia eólica mediante modelos estadísticos. Dentro de los que usan el análisis de series temporales se pueden comparar los modelos que pronostican directamente la potencia o los que la calculan a partir de la velocidad de viento.

En este enfoque se han realizado análisis y se ha llegado a la conclusión de que ninguno de los modelos muestra una ventaja significativa frente al otro. En el caso de los modelos con horizontes temporales cortos es importante tener la velocidad de viento como variable explicativa del modelo, mientras que para predicciones para horizontes temporales que exceden las 8-12 horas, la velocidad del viento no debería usarse para la predicción de potencia.

Debido a que este trabajo se enfoca en un horizonte temporal corto, se ha decidido modelizar las variables por separado.

2.6 Incertidumbre en la predicción

La predicción de la potencia eléctrica generada en el corto plazo por un parque eólico constituye una tarea difícil no exenta de errores. Dado que es imposible dar una predicción exacta, resulta útil proporcionar información sobre la incertidumbre asociada a la predicción, que servirá para conocer cómo se distribuye el error y poder manejar de forma óptima la producción eólica.

Un modo de dar información sobre la fiabilidad del pronóstico, y otorgar una estimación del error asociado a la predicción, es proporcionar intervalos de predicción que ofrecen una estimación de la probabilidad de que el valor real esté dentro de una cierta banda de confianza.

2.7 Sipleólico

El Sipleólico es un modelo por Red Eléctrica de España en colaboración con la Universidad Carlos III de Madrid, y que desde el año 2002 es utilizado como herramienta de predicción de viento de las siguientes 48 horas para la planificación del operador del sistema. Este modelo considera previsiones de viento basadas en metodologías físicas, las

Predicción de energía eólica mediante métodos probabilísticos a partir de series temporales de viento y potencia

cuales son complementadas con datos históricos y características propias de los parques, procesando todo con técnicas estadísticas.

Al estar enfocado como una herramienta para la programación del despacho energético, tiene un horizonte de corto plazo, mientras que en lo que refiere a su escala espacial usa una combinación entre un modelo macro-escalar (entregado por el ECMWF con datos cada 12 horas) y uno meso-escalar (entregados por HIRLAM cada 6 horas), que junto a una interpolación de los datos, dan la predicción para parques individuales o para pequeños parques que se encuentra cercanos.

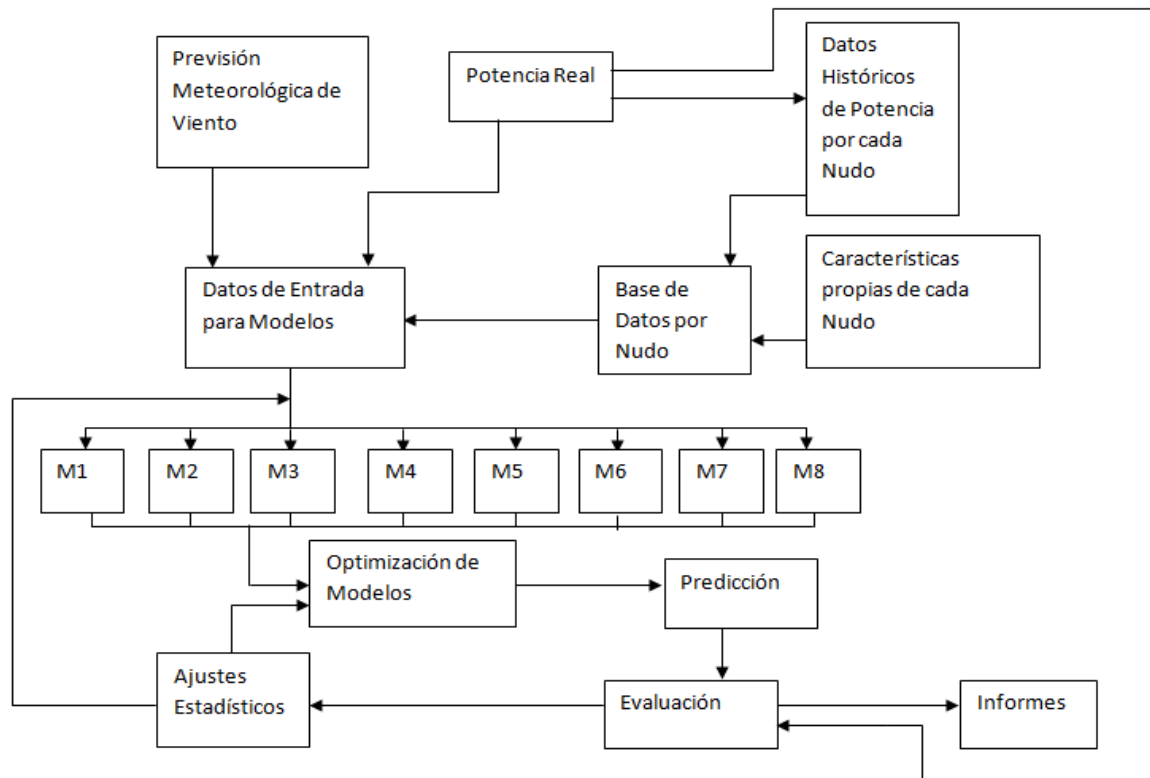


Figura 5: Esquema de funcionamiento de Sipleólico

Fuente: (Valdés & Vinagre, 2012)

La figura 5 es un esquema que representa el funcionamiento modular del Sipleólico. En ella podemos distinguir módulos que funcionan como datos de entrada para los modelos que componen al Sipleólico.

Sipleólico se compone por 8 modelos distintos cuyas predicciones serán ponderadas de una forma óptima para obtener una predicción final.

El mega-modelo tiene la capacidad de aprender mediante una evaluación continua resultante de comparar las predicciones de potencias con la potencia real. Esta evaluación se traduce en cambios en los parámetros de optimización de cada uno de los ocho modelos.

A continuación se pasa a revisar los módulos que componen el funcionamiento de Sipleólico (Valdés & Vinagre, 2012):

Previsión Meteorológica de Viento: Este módulo corresponde al módulo basado en la metodología física del Sipleólico. Las previsiones meteorológicas proceden de dos fuentes (HIRLAM y el ECMWF) que actualizan sus datos con una frecuencia de 4 y 2 veces al día respectivamente. Estos modelos son capaces de dar predicciones a 56 y 96 horas, con niveles de resolución bastante bajos. Sin embargo, el Sipleólico opta por estas fuentes por la rapidez con que generan datos nuevos, manteniendo el sistema actualizado.

Potencia Real: La potencia real es un dato de entrada que es actualizado en un intervalo de entre 10 y 20 minutos, responsabilidad de las oficinas del centro de control de Red Eléctrica de España. Esta oficina cuenta con "telemidas" recibidas de cada uno de los parques o nudos y contienen la información respecto a cuánta potencia está siendo generada en los parques.

Datos Históricos de Potencia por cada Nudo: Corresponden a los datos de potencia real durante todo el tiempo que el parque o nudo ha estado entregando datos a la oficina de control. Se puede pensar en ellos como una especie de curva de potencia empírica del parque o nudo en su conjunto. Estos datos deben, por supuesto, actualizarse cada vez que haya un cambio en los nudos, pues los datos antiguos no harán más que distorsionar las estimaciones.

Características Propias de cada Nudo: En este módulo se almacenan entre otros, la ubicación exacta del parque y la potencia total instalada. Otro dato interesante es la característica respecto a la orografía del lugar (muy sencilla, sencilla, compleja, muy compleja), que si bien no es necesaria para la estimación, sí puede explicar parte de ella. En general, las características hacen referencia a aquellos datos de los parques que no varían, o que al menos no varían en el corto plazo.

Base de Datos por Nudo: Tanto los datos históricos y las características propias de los nudos son almacenados en esta base de datos por nudo, con el objetivo de tener en un solo módulo todo lo necesario sobre un determinado nudo.

Datos de Entrada para Modelos: Este módulo tiene un propósito sobretodo funcional, y es simplemente una colección de todos los datos de entrada que serán procesados por los 8 modelos estadísticos. Se puede considerar que incluye datos de "memoria", los de la base de datos por nudo, y variables actualizadas correspondiente a la previsión meteorológica y la potencia instantánea real.

M1: Modelo de Persistencia. Este modelo fue el primero de los revisados, y considera que la potencia generada no cambia.

$$\hat{P}_{(t+h)1} = P_t$$

Donde P_t es la potencia generada en el instante t .

M2: Modelo Autorregresivo. Otro modelo puramente estadístico que no considera ninguna predicción física. Se tiene en cuenta la historia reciente, ponderando por un vector "a" para poder considerar cierta estacionalidad. El vector "a" puede variar entre los distintos instantes, de otra forma no se podría estudiar la estacionalidad de forma correcta.

$$\hat{P}_{(t+h)2} = a_{1t} * P_t + a_{2t} * P_{t-1} + \dots + a_{qt} * P_{t+1-q}$$

M3: Modelo Autorregresivo y Velocidad Lineal. Este modelo considera la previsión de velocidad obtenida de los modelos físicos meteorológicos, pero solo establece una relación lineal con la potencia futura, dependiente de la potencia actual y la estimación de la velocidad futura.

$$\hat{P}_{(t+h)3} = a_{0t} + a_{1t} * P_t + b_{1t} * \hat{v}_{t+h}$$

Los parámetros "a" y "b", dependen del instante en que se hace la predicción, con intención de poder incluir fenómenos como la estacionalidad y los errores de simulaciones anteriores.

M4: Modelo Autorregresivo con Velocidad Cuadrática. Este modelo se considera que la relación entre la potencia y la velocidad no es solo lineal, sino que también existe una linealidad con el cuadrado de la velocidad. Esto tiene bastante lógica si se tiene en cuenta que la potencia teórica es directamente proporcional al cubo de la velocidad.

$$\hat{P}_{(t+h)4} = a_{0t} + a_{1t} * P_t + b_{1t} * \hat{v}_{t+h} + b_{2t} * \hat{v}_{t+h}^2$$

M5: Modelo Autorregresivo con Velocidad Lineal y Dirección del Viento. En este caso se analiza no solo la magnitud del viento, sino también la dirección del movimiento. Únicamente se tiene en cuenta el movimiento de la dirección del viento en el plano paralelo a la superficie. Como se trata en dos dimensiones, basta con un ángulo plano para definirlo. Se usará $\phi_{(t+h)}$ como el valor de dicho ángulo.

$$\hat{P}_{(t+h)5} = a_{0t} + a_{1t} * P_t + b_{1t} * \hat{v}_{t+h} + c_{1t} * \sin\left(\frac{2 * \pi * \hat{\phi}_{t+h}}{360}\right) + c_{2t} * \cos\left(\frac{2 * \pi * \hat{\phi}_{t+h}}{360}\right)$$

M6: Modelo Autorregresivo con Velocidad Cuadrática y Dirección de Viento. Este modelo agrega la componente cuadrática a la previsión anterior, cambiando de paso el valor de todos los parámetros.

$$\begin{aligned} \hat{P}_{(t+h)6} = & a_{0t} + a_{1t} * P_t + b_{1t} * \hat{v}_{t+h} + b_{2t} * \hat{v}_{t+h}^2 + c_{1t} * \sin\left(\frac{2 * \pi * \hat{\phi}_{t+h}}{360}\right) \\ & + c_{2t} * \cos\left(\frac{2 * \pi * \hat{\phi}_{t+h}}{360}\right) \end{aligned}$$

M7: Modelo Autorregresivo y Predicción no Paramétrica basada en la velocidad y dirección. Este es un modelo que no usa una relación paramétrica entre la velocidad y la potencia, sino que utiliza una nueva variable $G_{(t+h)}$ cuyo valor representa la potencia dependiendo de una forma no paramétrica de la velocidad y su dirección. Esta relación está basada en la historia almacenada en el módulo de datos históricos por nudo.

$$\hat{P}_{(t+h)7} = a_{0t} + a_{1t} * P_t + d_{1t} * G_{t+h}$$

M8: Modelo de Predicción no Paramétrica basada en Velocidad y Dirección. Este modelo es una variación del anterior. La diferencia reside en que se elimina la autorregresión existente, de esta forma el valor futuro dependerá linealmente del valor obtenido de la predicción no paramétrica, la cual está basada en datos de potencia históricas en contra de datos de velocidad y dirección predicha.

$$\hat{P}_{(t+h)8} = a_{0t} + d_{1t} * G_{t+h}$$

Evaluación: Este módulo compara la potencia predicha para un instante, con la potencia real obtenida en dicho instante. Cada hora se libera un informe respecto a los posibles errores cometidos.

Ajustes Estadísticos: A partir de estos informes y de la memoria del mismo sistema, se realizan ajustes a los distintos parámetros y ponderadores usados tanto en los modelos como en el proceso de optimización. Se busca minimizar los errores medios. Este paso es altamente importante pues es donde el sistema aprende y mejora.

Comparación de los Modelos: Implica que el sistema debe ser capaz de procesar muchísimos datos, y llevar a cabo múltiples cálculos. Esto no es de ninguna forma una tarea sencilla, y para poder trabajar con los horizontes de tiempo utilizado, requiere el procesamiento en paralelo de cada nudo. Esto aumenta considerablemente el costo y la complejidad del sistema, además explica porqué no se hacen ciertas mejoras como un aumento de la resolución espacial, o la inclusión de los datos reales de velocidad para mejorar los modelos.

3. PRESENTACIÓN Y DEPURACIÓN DE DATOS

Para el desarrollo de este trabajo se disponen de datos cada diez minutos de velocidad de viento, temperatura y potencia eléctrica generada durante todo un mes. Hay que señalar que para la realización de este proyecto no se han tomado muestras y se asume que ellas, proporcionadas directamente, son los datos de partida que se deben analizar.

Debido a que no se tiene información de la dirección del viento ni la altura a la que están tomados, se asume para el desarrollo de este trabajo que todos los datos están tomados a la altura del buje del aerogenerador en la dirección de viento óptima para cada instante.

Para un adecuado uso de los datos, primeramente se deben eliminar aquellos valores atípicos y/o erróneos que puedan influir negativamente en la resolución del problema.

La depuración de datos consiste en el proceso de detección y corrección de datos incorrectos o corruptos de una base de datos. El proceso se utiliza principalmente cuando en alguna parte existen datos incorrectos, incompletos o irrelevantes que son identificados, y luego modificados, sustituidos o eliminados. La depuración de datos o *data cleansing* se ocupa de solucionar problemas de calidad de datos a dos niveles.

Por una parte, aborda los problemas relacionados con la entrada de datos en cuanto a valores redundantes o contradictorios, la unicidad del dato y su integridad referencial en datos procedentes de una fuente única.

Por otro lado, con datos provenientes de diversas fuentes, ayuda a solucionar los problemas de heterogeneidad, así como duplicidades, contradicciones e inconsistencias de los datos.

En este caso, se imponen como condiciones adicionales para la depuración de los datos, que tanto la velocidad del viento como la potencia generada tienen que ser mayor que cero. Asimismo, para el adecuado uso de la temperatura, se debe convertir los valores a grados Kelvin, puesto que de otra forma los valores negativos podrían influir en el análisis de forma significativa.

Con estas condiciones nos queda una base de datos con una cantidad final de 3197 datos para cada variable, es decir, 9591 valores en total.

Tiempo (min)	Velocidad (m/s)	Temperatura (K)	Potencia (MW)
10	4,342	279,932	100,699
20	5,105	279,940	151,095
30	5,559	279,948	241,800
40	4,192	279,95	54,624
50	3,707	279,999	6,471
60	3,688	280,007	35,855
70	2,840	280,041	3,643
80	3,728	280,049	14,515
90	4,559	280,058	113,393
100	4,033	280,066	37,255
110	3,765	280,075	86,596
120	4,961	280,083	152,899
.	.	.	.
.	.	.	.
.	.	.	.
.	.	.	.
31780	7,142	280,441	423,759
31790	7,541	280,365	622,375
31800	7,305	280,288	593,314
31810	8,215	280,211	765,873
31820	8,825	280,135	912,308
31830	9,163	280,058	1148,093
31840	9,956	279,982	1320,596
31850	10,247	279,905	1623,031
31860	11,098	279,829	1977,134
31870	12,375	279,752	1907,121
31880	13,028	279,676	1943,877
31890	10,127	279,599	1442,344
31900	9,5917	279,523	1389,267
31910	10,300	279,446	1209,644
31920	10,999	279,370	1714,279
31930	11,843	279,293	1875,638
31940	14,206	279,216	2008,794
31950	16,160	279,140	1990,066
31960	15,113	279,063	1975,221
31970	11,681	279	1983,559

Tabla 1: Datos de series temporales

4. SERIE TEMPORAL DE VELOCIDADES DE VIENTO

4.1 Distribuciones de probabilidad

En el estudio eólico es importante ser capaz de describir la variación de las velocidades de viento en una localización determinada, así como su probabilidad de ocurrencia. Es conveniente, por tanto, establecer un modelo de frecuencias que venga descrito por una función matemática continua en vez de por una tabla de valores discretos.

4.1.1 Distribución de Weibull

Es la función más utilizada para describir el comportamiento del viento y depende del parámetro de escala k (*shape*) y el parámetro de forma c (*scale*).

La velocidad del viento media o el parámetro de escala c , suele indicar cómo de ventoso es, en promedio, el emplazamiento. El parámetro de forma, k , indica cómo de puntiaguda es la distribución, es decir, si las velocidades del viento siempre tienden a estar próximas a un cierto valor, la distribución tendrá un alto valor de k .

$$d_p(V) = f(V) = \frac{k}{c} \left(\frac{V}{c}\right)^{k-1} \exp\left[-\left(\frac{V}{c}\right)^k\right]$$
$$F(V_x) = p(V \leq V_x) = \int_0^{V_x} d_p(V) dV = 1 - \exp\left[-\left(\frac{V}{c}\right)^k\right]$$

```
> summary(wei.fit)
Fitting of the distribution ' weibull ' by maximum likelihood
Parameters :
      estimate Std. Error
shape  1.942783 0.02666274
scale 10.602269 0.10205449
Loglikelihood: -9484.043   AIC: 18972.09   BIC: 18984.23
Correlation matrix:
      shape      scale
shape 1.0000000 0.3243721
scale 0.3243721 1.0000000
```

Tabla 2: Resumen de Weibull

En este caso se han ajustado los parámetros de escala y forma mediante el método de máxima verosimilitud (mle), dando como resultado $c=1.94$ y $k=10.6$, como puede observarse en la tabla 2.

Con estos parámetros, podemos representar la forma real que adopta la distribución para así evaluar su ajuste respecto a la distribución teórica.

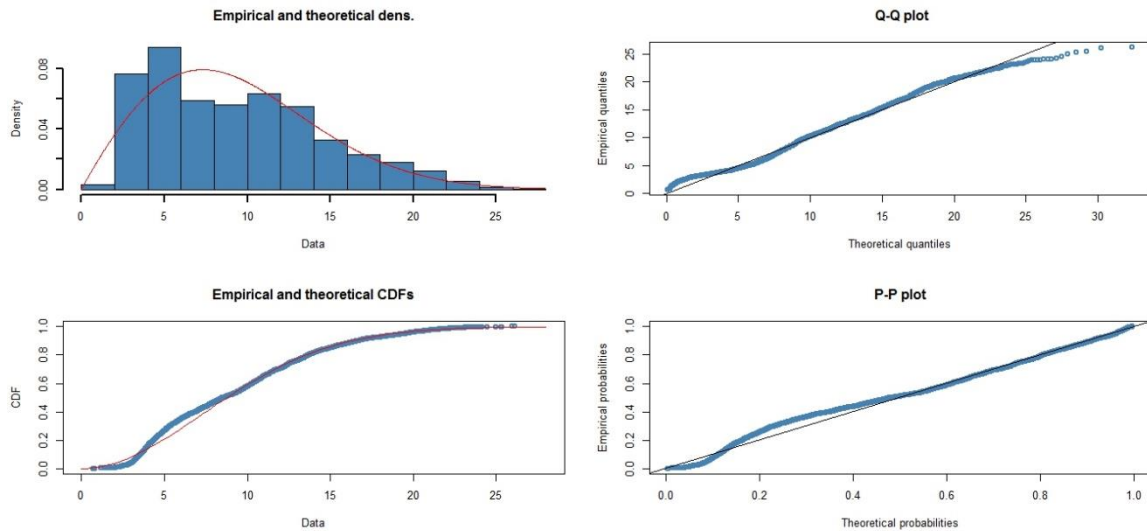


Figura 6: Resumen distribución Weibull

En la figura 6 se representa con líneas rojas la distribución teórica estudiada, en este caso la distribución de Weibull, y en azul la distribución real que siguen los datos. Cuanto más se aproximen los datos reales (azul) a las líneas teóricas (rojas), mayor será el grado de verosimilitud.

4.1.2 Distribución de Rayleigh

Esta distribución es un caso particular de la distribución de Weibull donde el factor de forma toma el valor de dos ($k=2$), simplificando el modelo, el cual depende así de tan solo un parámetro.

$$d_p(V) = f(V) = \frac{2V}{c^2} \exp\left[-\left(\frac{V}{c}\right)^2\right]$$

$$F(V_x) = p(V \leq V_x) = \int_0^{V_x} d_p(V) dV = 1 - \exp\left[-\left(\frac{V}{c}\right)^2\right]$$

```
> summary(ray.fit)
Fitting of the distribution 'rayleigh' by maximum likelihood
Parameters :
  estimate Std. Error
1 7.546741 0.0667461
Loglikelihood: -9486.278  AIC: 18974.56  BIC: 18980.62
```

Tabla 3: Resumen de Rayleigh

Una vez se ha estimado el parámetro de escala c , obtenido en la tabla 3, se puede observar que al ser el factor de forma semejante al que sigue la distribución de Weibull y ser el modelo más simple, ambos son muy similares.

El AIC (*Akaike Information Criterion*), muestra la relación entre la bondad de ajuste y su complejidad, es decir, la complejidad del modelo en cuestión. Cuanto menor sea el AIC, más simple es el modelo. Este criterio de simplicidad se usa cuando se deben elegir entre

varios modelos de resultados similares, ya que ahorra tiempo de cálculo y recursos computacionales.

La similitud entre la distribución de Weibull y de Rayleigh también se ve reflejado en la figura 7, donde si se compara con la anterior (figura 6), apenas existen diferencias.

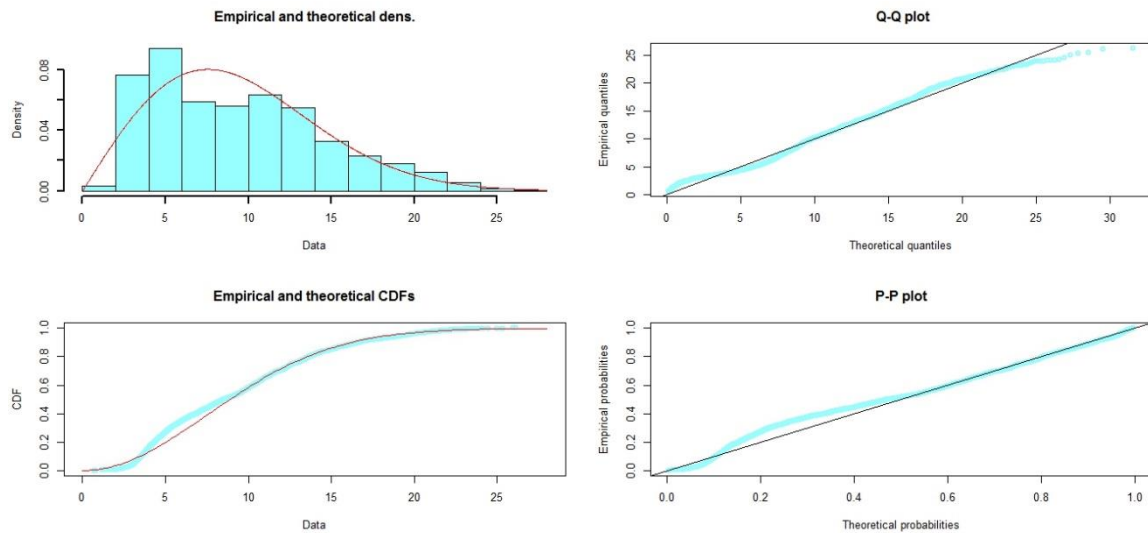


Figura 7: Resumen distribución Rayleigh

Se puede concluir, por consiguiente, que con estos datos se podría usar una distribución de Rayleigh sin que esto suponga un gran error, simplificando así el cálculo.

4.1.3 Distribución de Gumbel

La distribución de Gumbel se basa en la teoría de valores extremos, la cual analiza la probabilidad de eventos o valores más extremos que los observados previamente, por lo que esta distribución es adecuada para determinar las velocidades excesivas de viento y analizar la posible velocidad de parada del aerogenerador.

$$d_p(V) = f(V) = \frac{e^{-\frac{\mu-x}{s}} e^{-\frac{\mu-x}{s}}}{s}$$

$$F(V_x) = p(V \leq V_x) = \int_0^{V_x} d_p(V) dV = \exp\left(-e^{-\frac{x-\mu}{s}}\right)$$

Realizando el ajuste de la función de distribución mediante el método de máxima verosimilitud para los parámetros μ y s se obtiene:

```

> summary(gumbel.fit)
Fitting of the distribution ' gumbel ' by maximum likelihood
Parameters :
  estimate Std. Error
mu 6.974103 0.07454185
s  4.003446 0.05749747
Loglikelihood: -9531.748   AIC: 19067.5   BIC: 19079.63
Correlation matrix:
      mu      s
mu 1.000000 0.3112943
s  0.3112943 1.0000000
    
```

Tabla 4: Resumen de Gumbel

Como se puede apreciar en la tabla 4, el ajuste de esta distribución es peor que las dos anteriores, lo cual se puede constatar comparándolo con la distribución teórica.

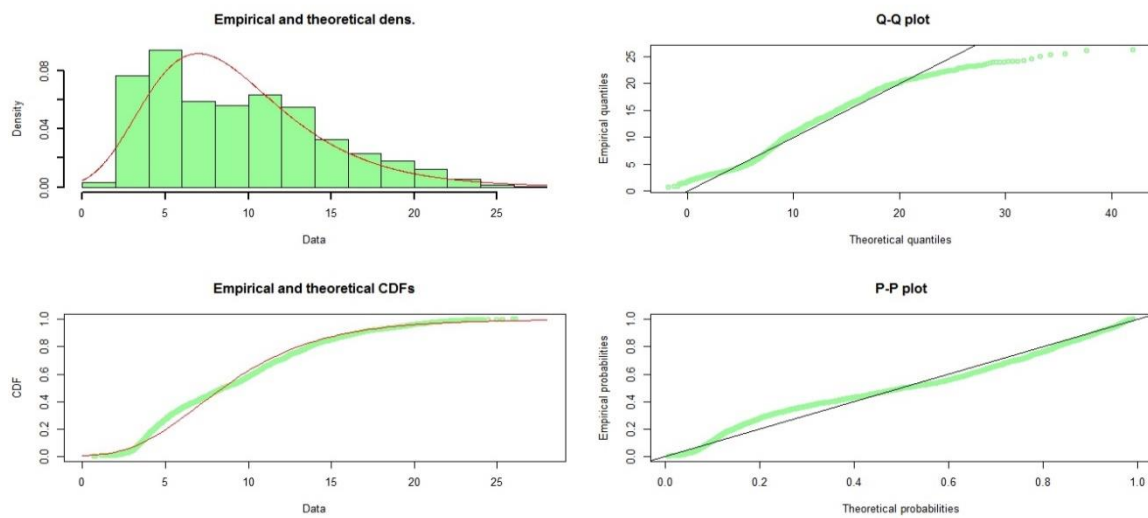


Figura 8: Resumen distribución Gumbel

En la figura 8 se observa una mayor desviación de los datos reales (verde) frente a la distribución teórica (roja).

Finalmente, para determinar cuál de las distribuciones es mejor, podemos comparar varios criterios de bondad de ajuste:

Goodness-of-fit statistics/ Distribution	Weibull	Rayleigh	Gumbel
Kolmogorov-Smirnov statistics	0,06943	0,07997	0,07826
Cramer-von Mises statistics	3,28298	4,32571	5,38842
Anderson- Darling statistics	22,7615	27,76198	33,33431
Aikake's Information Criterion	18972,09	18974,56	19067,5
Bayesian Information Criterion	18984,23	18980,62	19079,63

Tabla 5: Comparación de distribuciones

Como era de esperar, la distribución de Weibull es la que mejor ajuste tiene ya que sus criterios son los menores en comparación.

4.2 Análisis descriptivo

Una vez tratado los datos correctamente, se dispone de una serie temporal de velocidades de viento (X_t), cuyo comportamiento a lo largo del tiempo se describe a través de sus cuatro componentes principales: tendencia, componente cíclica, componente estacional y variaciones aleatorias.

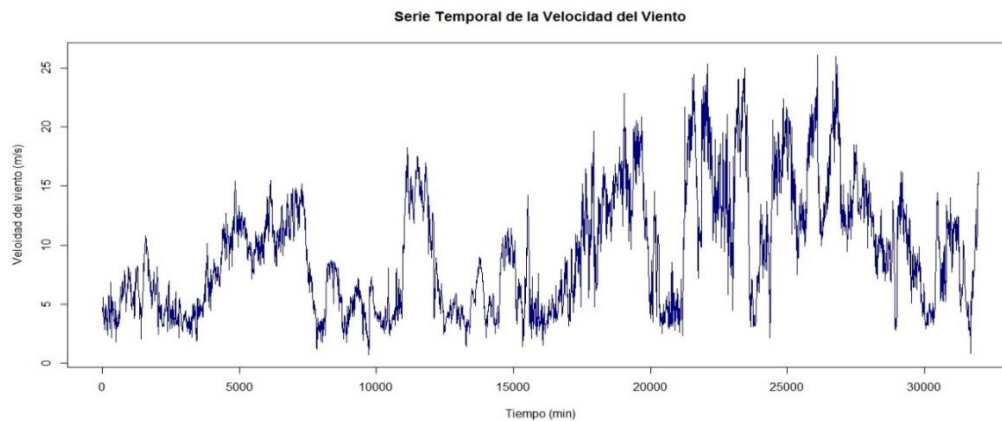


Figura 9: Serie temporal de la velocidad del viento

Representada la serie temporal (figura 9), se puede observar que la tendencia varía sin un patrón marcado y no se aprecia ninguna componente estacional. Además, al ser una serie de tan solo un mes, no se puede extraer información de su componente cíclica, pues ésta solo se contempla en periodos de mínimo un año.

Para poder hacer un análisis más exhaustivo de la serie, se procede a realizar su descomposición mediante el método de descomposición STL (*Seasonal Trend Decomposition using Loess*), el cual está basado en un método de suavizado por regresión local y permite descomponer la serie en tres componentes: tendencia (trend), estacionalidad (seasonal) y aleatoria (remainder).




Figura 10: STL de la velocidad del viento

Tras la descomposición de la serie (figura 10), se puede corroborar que la tendencia no sigue un patrón, lo que implica que la serie no es estacionaria en media, y que presenta una estacionalidad subyacente de esquema aditivo, la cual no es de mucha importancia debido a que tras separar los componentes, la parte aleatoria sigue siendo aún muy acusada. Es por esto que la componente estacional no se tendrá en cuenta a la hora de modelizar.

Además, la serie no tiene varianza constante, la cual parece variar de forma proporcional con el tiempo. Estas conclusiones se pueden confirmar en la figura 11 con sus correlogramas simple y parcial, donde la ACF² presenta un decrecimiento lento y lineal mientras que la PACF³ presenta el primer coeficiente con un valor próximo a la unidad.




Figura 11: ACF y PACF de velocidad de viento

Por tanto, hace falta aplicar una diferencia regular para convertir la media constante y hacer una transformación logarítmica para estabilizar la varianza.




Figura 12: Análisis de la transformación de la velocidad del viento

Tras realizar las transformaciones necesarias, la serie modificada (W_t) muestra un aspecto como el observado en la figura 12, donde aparentemente es estable en media y

² ACF: correlograma simple o *autoregressive correlated function*

³ PACF: correlograma parcial o *partial autoregressive correlated function*

varianza. Por otra parte, el ACF y el PACF muestran un comportamiento que ayudará a determinar los modelos tentativos a estudiar.

$$Z_t \sim ARIMA(0,1,0)$$

$$W_t = \nabla Z_t = (1 - B)Z_t = Z_t - Z_{t-1} = a_t$$

$$Z_t = \text{Ln}(X_t)$$

Aplicando la transformación de diferencia regular de forma implícita en la fórmula que define la predicción, se queda que para un instante, (Z_t) es una transformación logarítmica de la serie original para ese mismo instante de tiempo (X_t) .

4.3 Estimación, diagnóstico y validación de modelos tentativos

Según la metodología Box-Jenkins, una vez se ha identificado un modelo tentativo, se debe llevar a cabo la estimación de los parámetros que lo caracterizan. A este proceso se le conoce como análisis de significación. Además, habrá que verificar que dichos parámetros estimados son significativamente distintos de cero y cumplen las condiciones de estacionariedad y/o invertibilidad.

Tras la fase de estimación y diagnosis se llega a la etapa de validación, donde se debe comprobar si los residuos del modelo ajustado siguen un proceso de ruido blanco, es decir, siguen una distribución normal, tienen media nula, su varianza es constante y están incorrelacionados.

Tras esto, se podrán comparar con otros modelos también válidos para realizar predicciones.

4.3.1 ARIMA (0, 1, 2)

De la observación de la ACF y la PACF, se puede deducir que la serie W_t sigue una estructura de tipo de medias móviles de orden dos en su parte regular. Luego, se prueba un modelo tentativo $W_t \sim MA(2) \rightarrow Z_t \sim ARIMA(0,1,2)$.

$$Z_t = \text{Velocidad de viento}$$

$$Z_t \sim ARIMA(0,1,2)$$

$$\nabla Z_t = \theta_2(B)a_t$$

$$(1 - B)Z_t = (1 - \theta_1 B - \theta_2 B^2)a_t$$

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
MA(1)	0,353344	0,0176707	19,9961	0,000000
MA(2)	0,055856	0,0177101	3,1539	0,001611

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 0,0395274 con 3194 grados de libertad

Desviación estándar estimada de ruido blanco = 0,198815

Número de iteraciones: 2

Tabla 6: Resumen Statgraphics del modelo de velocidad de viento ARIMA (0,1,2)

Una vez se han estimado los parámetros se debe verificar si se cumple la hipótesis de significación usando el estadístico “T” o en su defecto el “p-value”.

$$T = \left| \frac{\hat{p}_i}{desv. tip(\hat{p}_i)} \right|$$

Para un nivel de significación del 5%, se podrá aceptar la hipótesis de no significación si $T > 2$ o si el $p - value < 0.05$. En este caso, tanto los coeficientes θ_1 y θ_2 son significativos al 5%.

Para comprobar los requisitos de estacionariedad e invertibilidad se debe contrastar que las raíces de los polinomios autorregresivos y/o de medias móviles son, en módulo, mayores que la unidad.

Para el proceso ARIMA(0,1,0), como solo tiene estructura de medias móviles, será siempre estacionario, e invertible cuando sus raíces en módulo sean mayores que la unidad.

$$(1 - \theta_1 B - \theta_2 B^2)a_t = (1 - 0.3534B - 0.0558B^2)a_t$$

$$|B| = \left| \frac{0.3534 \pm \sqrt{(-0.3534)^2 + 4 \cdot 0.0558}}{-2 \cdot 0.0558} \right|$$

$$raíz_1 = 8.45$$

$$raíz_2 = 2.12$$

Por tanto, el proceso sí es invertible. También se puede conocer si el proceso lo es comprobando que cumple las siguientes condiciones:

$$(\theta_1 + \theta_2) < 1 ; 0.3534 + 0.0558 = 0.4092 < 1$$

$$(\theta_2 - \theta_1) < 1 ; 0.0558 - 0.3534 = -0.2976 < 1$$

$$|\theta_2| < 1 ; |0.0558| < 1$$

Finalizada la etapa de diagnosis, se llega a la fase de validación, la cual consiste en comprobar si los residuos se comportan como un proceso de ruido blanco.

Lo primero que se debe demostrar es si los correlogramas ACF y PACF de la serie residual de modelo ajustado son independientes entre sí.

Predicción de energía eólica mediante métodos probabilísticos a partir de series temporales de viento y potencia

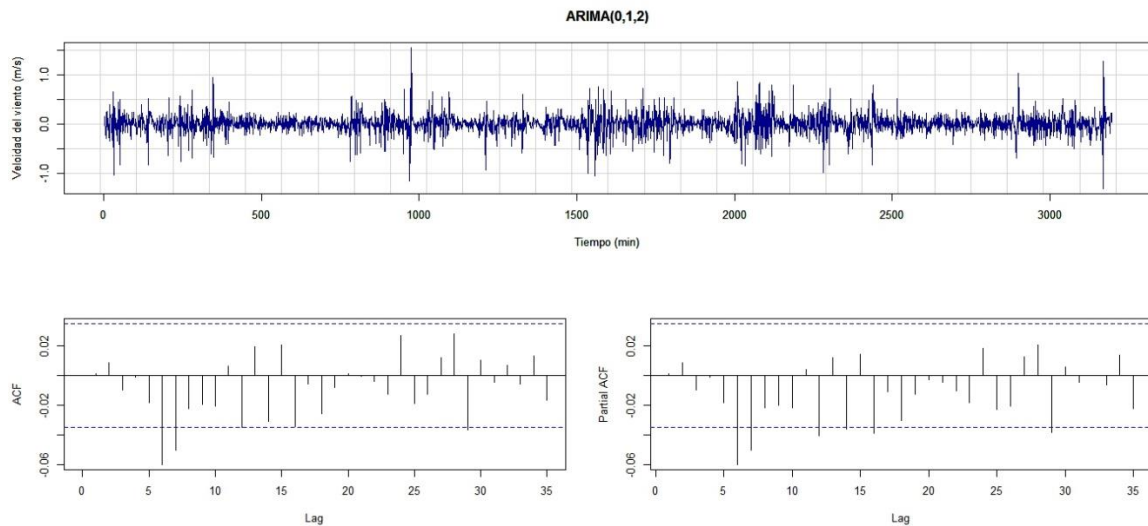


Figura 13: Correlogramas ARIMA (0,1,2)

La figura 13 nos muestra la serie residual obtenida y la ACF y PACF de la misma. Como se puede observar, casi todos los coeficientes caen dentro de las bandas de confianza y por tanto se concluye que el modelo capta casi toda la estructura de autocorrelación de la serie original.

Se debe comprobar además si los residuos siguen una distribución normal con media cero, lo cual se observa en la siguiente imagen (figura 14) en la que se muestra el histograma y el gráfico Box-Whisker.

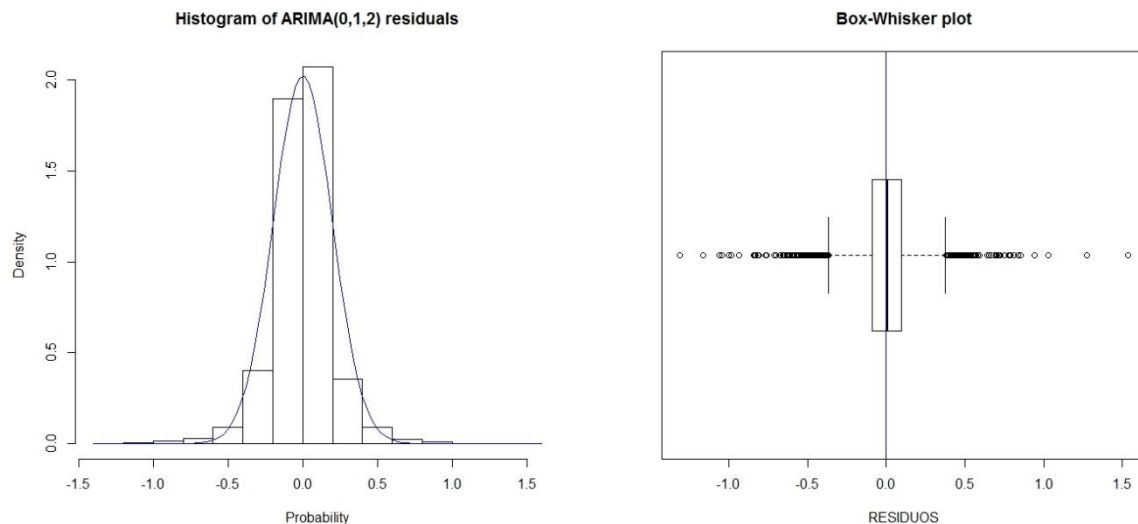


Figura 14: Análisis de la distribución normal del ARIMA (0,1,2)

Finalmente, para estar completamente seguros que el modelo ajustado recoge la suficiente información de la serie y es por tanto un buen modelo, se puede observar el periodograma acumulado de los residuos (figura 15).

En dicho diagrama se contrasta la hipótesis de que los datos siguen una determinada distribución, una normal en este caso, mediante la prueba de bondad de ajuste de

*Kolmogorov-Smirnov*⁴, para los niveles de significación de 95% y 99%. Por tanto, si los residuos caen dentro de ambas bandas, se puede considerar que los residuos se comportan mediante una normal.




Figura 15: Periodograma ARIMA (0,1,2)

Se contrasta por tanto que el modelo tentativo $Z_t \sim ARIMA(2,1,2)$ cumple con los requisitos de diagnosis y validación y hay que tenerlo en cuenta para la fase de predicción.

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$Z_t = Z_{t-1} + a_t - 0.3534a_{t-1} - 0.0558a_{t-2}$$

4.3.2 ARIMA (2, 1, 2)

Una forma alternativa de obtener un modelo tentativo es usando la función "auto.arima" del software estadístico de código libre "R", la cual devuelve un posible modelo tentativo. Para estos datos, la función ha devuelto un modelo $Z_t \sim ARIMA(2,1,2)$

$$Z_t \sim ARIMA(2,1,2)$$

$$\phi_2(B)\nabla Z_t = \theta_2(B)a_t$$

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B)Z_t = (1 - \theta_1 B - \theta_2 B^2)a_t$$

$$[1 - (\phi_1 + 1)B + (\phi_1 - \phi_2)B^2 + \phi_2 B^3]Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$Z_t - (\phi_1 + 1)Z_{t-1} + (\phi_1 - \phi_2)Z_{t-2} + \phi_2 Z_{t-3} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$Z_t = (\phi_1 + 1)Z_{t-1} - (\phi_1 - \phi_2)Z_{t-2} - \phi_2 Z_{t-3} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

Ahora bien, hay que estimar los parámetros y comprobar que son significativos.

⁴ En estadística, la prueba de *Kolmogorov-Smirnov* (también prueba K-S) es una prueba no paramétrica que determina la bondad de ajuste de dos distribuciones de probabilidad entre sí.

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
AR(1)	-0,148303	0,998384	-0,148543	0,881910
AR(2)	0,0377766	0,132913	0,284219	0,776238
MA(1)	0,209049	0,997788	0,209512	0,834044
MA(2)	0,139379	0,492409	0,283056	0,777130

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 0,0388723 con 3247 grados de libertad

Desviación estándar estimada de ruido blanco = 0,197161

Número de iteraciones: 4

Tabla 6: Resumen de modelo de velocidad de viento ARIMA (2,1,2)

Como se puede observar en la tabla 8, esta vez los parámetros no son significativos, puesto que el “p-value” de cada uno de ellos es mayor que 0,05.

Esto implica que aunque el modelo pueda recoger la mayoría de información de los datos y los residuos se ajusten a un proceso de ruido blanco (figura 16), no es adecuado utilizarlo para realizar predicciones.

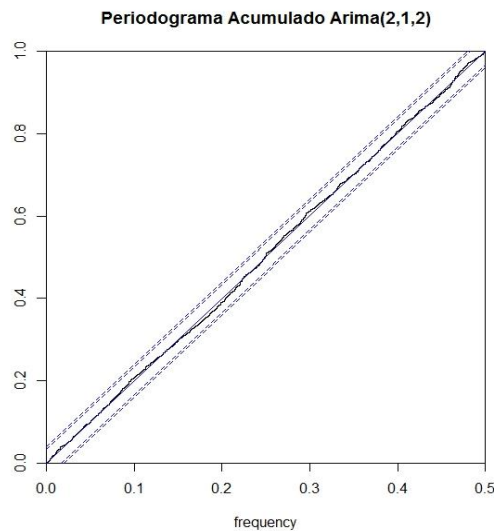


Figura 16: Periodograma ARIMA (2,1,2)

4.3.3 ARIMA (1, 0, 1)

Otro modelo tentativo se podría obtener mediante la opción de “pronóstico automático” que ofrece el programa Statgraphics.

Esta vez el modelo elegido mediante el criterio de menor AIC, es decir, con mayor sencillez y buen resultado, es el $Z_t \sim ARIMA(1,0,1)$

$$Z_t \sim ARIMA(1,0,1)$$

$$\phi_1(B)Z_t = \theta_1(B)a_t$$

$$(1 - \phi_1 B)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = \phi_1 Z_{t-1} + a_t - \theta_1 a_{t-1}$$

Siguiendo con el proceso de diagnóstico y validación, se comprueba que los parámetros son significativos.

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
AR(1)	0,99612	0,00160221	621,717	0,000000
MA(1)	0,370489	0,0163941	22,599	0,000000

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 2,32803 con 3250 grados de libertad

Desviación estándar estimada de ruido blanco = 1,52579

Número de iteraciones: 8

Tabla 7: Resumen de modelo de velocidad de viento ARIMA (1,0,1)

Esta vez ambos parámetros tienen el p-value < 0.05 y por lo tanto la estimación de los parámetros es correcta.

El siguiente paso será comprobar si el proceso cumple las condiciones de estacionariedad e invertibilidad.

El proceso Z_t será estacionario si $|\phi_1| < 1$ e invertible si $|\theta_1| < 1$. Para este modelo se cumplen ambas condiciones y por tanto Z_t es estacionario e invertible.




Figura 17: Correlogramas ARIMA (1,0,1)

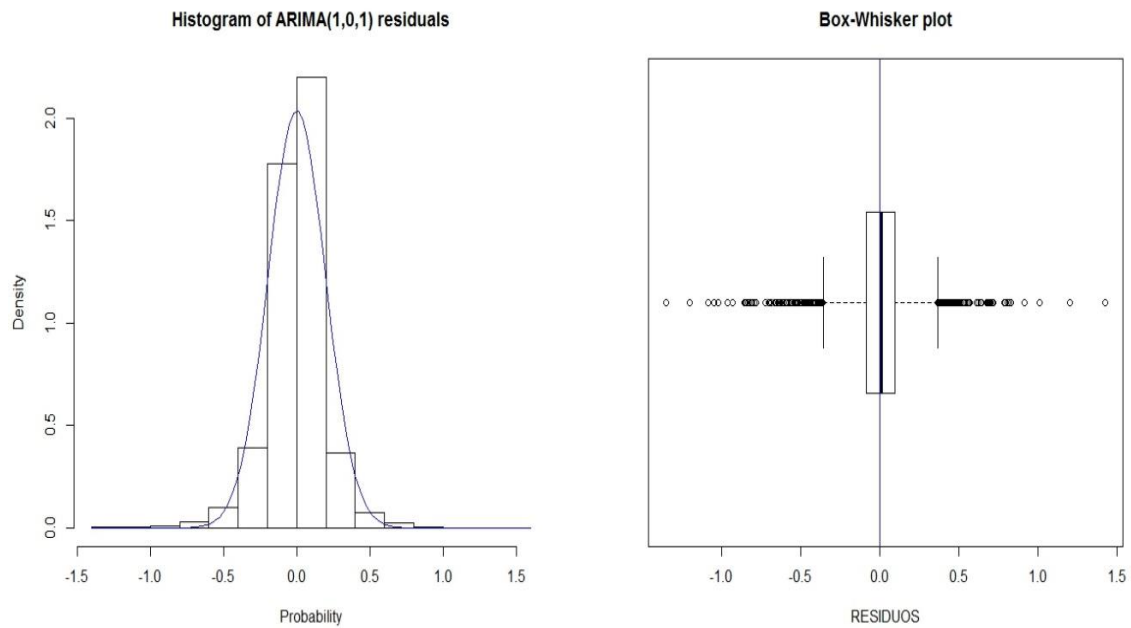


Figura 18: Análisis de la distribución normal del ARIMA (1,0,1)

Analizando los residuos se observa que sus correlogramas caen dentro de las bandas de confianza y que se distribuye según una normal con media cero. Se destaca del gráfico de Box-Whisker, los datos anómalos a causa de ser datos reales, los cuales no se pueden eliminar debido a que a su vez se producirían más, ya que los residuos se asemeja a ruido blanco, y por tanto, a un proceso aleatorio.

Con el periodograma integrado de los residuos se verifica que pasan el test de Kolmogorov-Smirnov con el 95% y 99% de confianza, aunque para frecuencias que se encuentran entre 0.2 y 0.4 se aleja de la media y se aproximan bastante al límite, lo que implica que es algo peor que el primer modelo analizado.




Figura 19: Periodograma acumulado velocidad de viento ARIMA (1,0,1)

4.3.4 Comparación de modelos

Por último, se debe realizar una comparación de los modelos tentativos disponibles para estudiar así su efectividad, esto es, qué error existe entre los datos y el pronóstico. Para esto se utilizan diferentes estadísticos como son el RMSE (raíz del error cuadrado medio), MAE (error absoluto medio), MAPE (porcentaje de error absoluto medio), ME (error medio) y MPE (porcentaje de error medio).

Los tres primeros estadísticos miden la magnitud de los errores, de tal modo que un mejor modelo daría un valor más pequeño, mientras que los dos últimos estadísticos miden el *bias* o sesgo, donde el modelo será mejor cuanto más cercano a cero sea el valor.

Comparación de Modelos

Variable de datos: Velocidad
 Número de observaciones = 3252
 Índice Inicial = 1,0
 Intervalo de Muestra = 1,0

Modelos

(A) ARIMA(0,1,2)
 Ajuste matemático: Log natural
 (B) ARIMA(1,0,1)
 Ajuste matemático: Log natural

Periodo de Estimación

Modelo	RMSE	MAE	MAPE	ME	MPE
(A)	1,53445	1,06747	13,8022	0,0559153	-1,9627
(B)	1,53256	1,06667	13,7565	0,102602	-1,45956

Tabla 8: Comparación de modelos para la velocidad de viento

Observando la tabla 10 se determina que ambos son muy parecidos entre sí en cuanto a precisión.

Finalmente se decide elegir el modelo $Z_t \sim ARIMA(0,1,2)$ debido a que se ha construido paso a paso mediante la metodología Box-Jenkins.

4.4 Predicción

Una vez realizada la búsqueda de un modelo que explique el comportamiento de la serie temporal, se ejecuta la predicción de lo que ocurrirá en un futuro inmediato. La tipología de herramientas de análisis y predicción de series temporales utilizadas en este proyecto son de naturaleza proyectiva, caracterizada por la hipótesis de constancia del entorno, es decir, las condiciones del entorno permanecen constantes, lo cual se puede mantener en un horizonte a corto plazo. Además, las predicciones se realizarán de forma puntual y por intervalos de confianza.

La predicción puntual trata de estimar los valores futuros de la variable Z_t con la información disponible proyectando su pasado. Así, denotamos por Z_{t+k} a la predicción de Z_t con horizonte de k periodos hacia delante.

Además, es bastante útil contar con bandas de confianza donde con alta probabilidad se pueda encontrar el valor de la serie en un instante futuro, por lo que se realizan bandas de confianza para la predicción al 95% mediante la expresión:

$$\hat{Z}_t = \pm 2 \text{desv. típica}[e_t(k)]$$

Donde $\text{desv. típica}[e_t(k)]$ es la desviación típica estimada del error de predicción a un horizonte de k periodos.

Desarrollando la ecuación de predicción del modelo seleccionado:

$$\text{Velocidad de viento} = Z_t \sim \text{ARIMA}(0,1,2) \text{ sin constante}$$

$$\nabla Z_t = \theta_2(B)a_t$$

$$(1 - B)Z_t = (1 - \theta_1 B - \theta_2 B^2)a_t$$

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$Z_t = Z_{t-1} + a_t - 0.3534a_{t-1} - 0.0558a_{t-2}$$

En este caso, la serie fue previamente transformada logarítmicamente para estabilizar la varianza. Luego el modelo correcto sería:

$$(1 - B)\text{Ln}(X_t) = (1 - \theta_1 B - \theta_2 B^2)a_t$$

Con $\theta_1 = 0.3534$, $\theta_2 = 0.0558$ y X_t la serie original "Velocidad del viento".

Esta transformación se realiza directamente en el módulo de series temporales en "Statgraphics" y por tanto la siguiente tabla muestra las predicciones en las unidades correctas.

		Límite en 95,0%	Límite en 95,0%
Periodo	Pronóstico	Inferior	Superior
3198,0	12,7098	8,52648	18,9456
3199,0	12,8999	8,04439	20,6861
3200,0	12,8999	7,63898	21,7839
3201,0	12,8999	7,28791	22,8333
3202,0	12,8999	6,97799	23,8474
3203,0	12,8999	6,7005	24,835
3204,0	12,8999	6,44932	25,8022
3205,0	12,8999	6,21998	26,7536
3206,0	12,8999	6,00908	27,6926
3207,0	12,8999	5,814	28,6218
3208,0	12,8999	5,63264	29,5433
3209,0	12,8999	5,46332	30,4589

Tabla 9: Predicción del viento en m/s

Los pronósticos se han calculado para un intervalo de 12 periodos, es decir, 2 horas.

Además, se pueden representar las bandas de confianza para el pronóstico de un día, limitando la banda superior a valores lógicos.

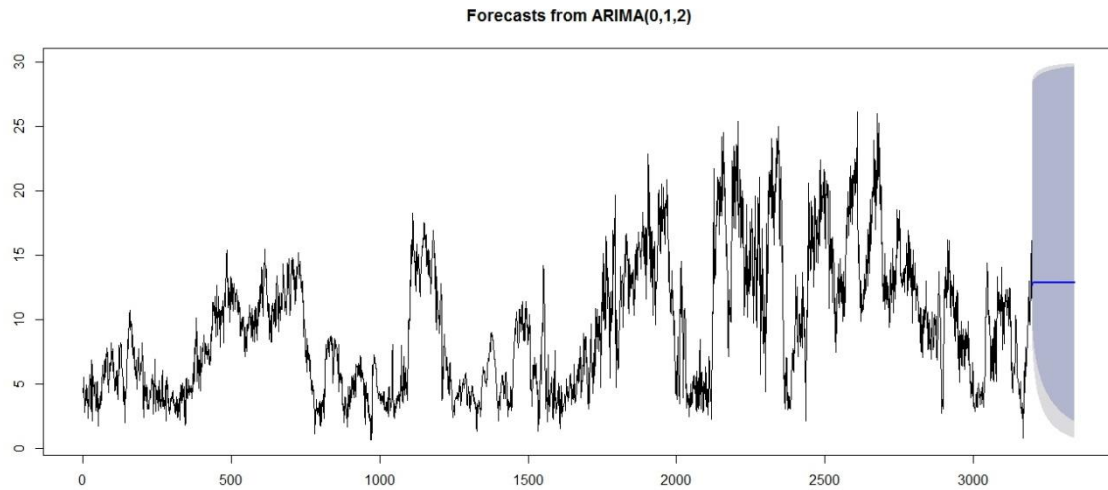


Figura 20: Predicción ARIMA (0,1,2)

En la figura 20 se representa la serie temporal de la velocidad de viento siendo el eje de ordenadas el periodo y el eje de abscisas la velocidad del viento. Se muestra en azul una línea constante representando el valor de la predicción para tiempos futuros y en azul más claro una banda de confianza del 95% en el que es posible que finalmente se encuentre la velocidad real.

En el análisis estadístico, la banda de confianza aumenta mucho cuanto más se aleja en el tiempo, por lo que en este caso se decide limitar la velocidad superior a valores extremos lógicos.

5. SERIE TEMPORAL DE TEMPERATURA

5.1 Análisis descriptivo

Para el estudio de la potencia eólica es necesario conocer, a parte de la velocidad del viento, la densidad del aire que atraviesa la turbina. A su vez, la densidad del aire varía con la temperatura ambiente, por lo que se realizará un modelo predictivo para calcular su valor en los instantes futuros.

Primeramente, al igual que para la velocidad del viento, se debe efectuar el análisis descriptivo de la serie temporal y desarrollar las operaciones necesarias para estabilizar la media y la varianza.

En la siguiente imagen (figura 21) se muestra la serie temporal de la temperatura ambiente:

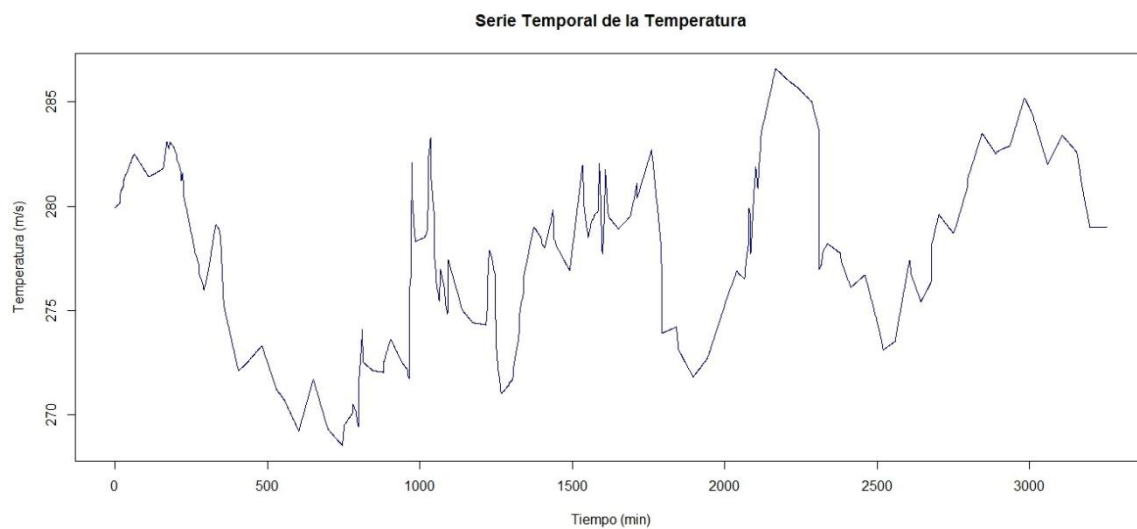


Figura 21: Serie temporal de la temperatura

A primera vista, no hay indicios de no estabilidad en varianza, por lo que esta vez no será necesario aplicar la metodología de Box-Cox. A su vez, se deduce que la serie no es estable en media, pues tiene una tendencia muy marcada. Esto se demuestra en la representación de los correlogramas ACF y PACF.




Figura 22: Correlogramas de la temperatura

Nuevamente se observa un decaimiento progresivo hacia cero en la ACF, lo cual indica la necesidad de derivar la parte regular.

Una vez derivada, la serie tiene un aspecto tal y como muestra la figura 23, donde ahora es más difícil determinar de forma rápida un modelo tentativo según Box-Jenkins.




Figura 23: Análisis de la transformación de la serie de temperatura

Esta vez, los correlogramas no muestran de forma sistemática un comportamiento autorregresivo o de medias móviles, y cabe la posibilidad de formar una combinación de ambos.

Además, del gráfico de la secuencia cronológica se puede observar diferentes datos anómalos, siendo el más significativo el que alcanza un valor de -6.5.

5.2 Estimación, diagnóstico y validación de modelos tentativos

5.2.1 ARIMA (1, 1, 1)

Dado que a partir de la estructura de los correlogramas no se identifica claramente un modelo, se decide empezar a probar con el modelo tentativo $Z_t \sim ARIMA(1,1,1)$.

$$Z_t \sim ARIMA(1,1,1)$$

$$\phi_1(B)\nabla Z_t = \theta_1(B)a_t$$

$$(1 - \phi_1 B)(1 - B)Z_t = (1 - \theta_1 B)a_t$$

$$(1 - (1 + \phi_1)B + \phi_1 B^2)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = (1 + \phi_1)Z_{t-1} - \phi_1 Z_{t-2} + a_t - \theta_1 a_{t-1}$$

Hecho su desarrollo, se procede a la fase de diagnóstico y análisis, donde se comprueban la significación de los parámetros.

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
AR(1)	0,723098	0,0476159	15,1861	0,000000
MA(1)	0,541362	0,0563338	9,6099	0,000000

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 0,0443579 con 3249 grados de libertad

Desviación estándar estimada de ruido blanco = 0,210613

Número de iteraciones: 7

Tabla 10: Resumen de modelo de temperatura ARIMA (1,1,1)

Como se observa en la tabla 12, ambos parámetros cumplen los criterios de significación, por lo tanto el siguiente paso es verificar que tanto $|\phi_1|$ y $|\theta_1| < 1$, lo cual se cumple, por lo que el modelo Z_t es estacionario e invertible.

Además, se comprueba que los residuos siguen una distribución normal en la mayoría de valores y que tienen media en cero, por lo que se pueden considerar casi ruido blanco. El periodograma integrado de los residuos cumple con los intervalos de confianza.

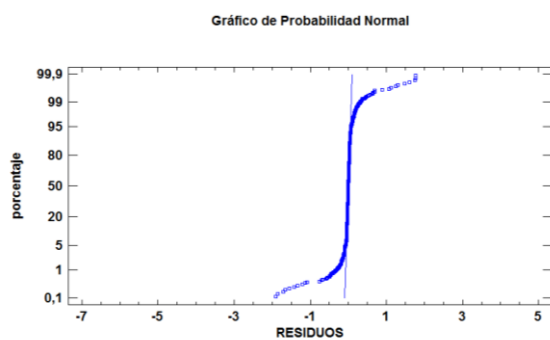


Figura 24: Gráfico de probabilidad normal del ARIMA(1,1,1)

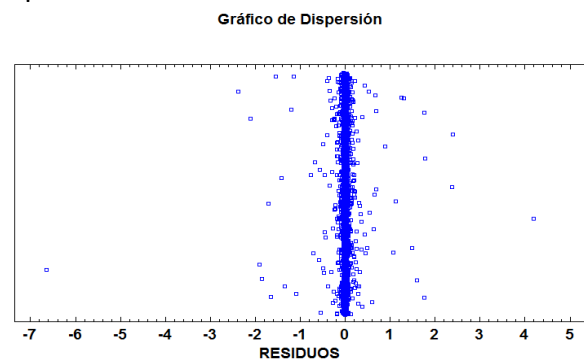


Figura 25: Gráfico de dispersión del ARIMA (1,1,1)




Figura 26: Periodograma acumulado de temperatura del ARIMA (1,1,1)

5.2.2 ARIMA (2, 1, 0)

Otro modelo tentativo es $Z_t \sim ARIMA(2,1,0)$

Observando el PACF de la serie temporal una vez integrada se puede probar con un término autorregresivo de orden dos.

$$\begin{aligned} \phi_2(B)\nabla Z_t &= a_t \\ (1 - \phi_1 B - \phi_2 B^2)Z_t &= a_t \\ Z_t &= \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + a_t \end{aligned}$$

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
AR(1)	0,191631	0,0175651	10,9098	0,000000
AR(2)	0,120682	0,0175654	6,87043	0,000000

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 0,0452829 con 3194 grados de libertad

Desviación estándar estimada de ruido blanco = 0,212798

Número de iteraciones: 1

Tabla 11: Resumen de modelo de temperatura ARIMA (2,1,0)

De nuevo se comprueba que los parámetros son significativos y que ambos son menores, en módulo, que uno, por lo que el modelo es estacionario e invertible.

Predicción de energía eólica mediante métodos probabilísticos a partir de series temporales de viento y potencia




Figura 27: Gráfico de probabilidad normal del ARIMA(2,1,0)

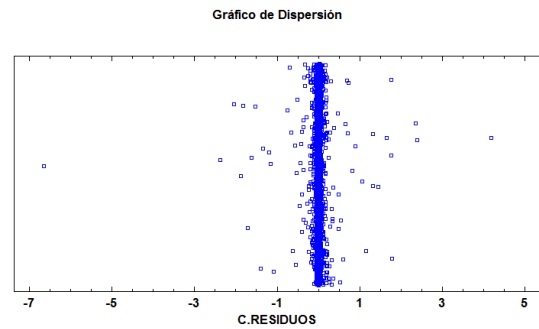


Figura 28: Gráfico de dispersión del ARIMA (2,1,0)




Figura 29: Periodograma acumulado de temperatura del ARIMA (2,1,0)

Observando las gráficas (figuras 27, 28 y 29) se verifica que el modelo cumple con la validación necesaria para considerarse casi ruido blanco y recoge la suficiente información de la serie temporal.

5.2.3 Comparación de modelos

Una vez se han propuesto modelos tentativos, se comparan entre ellos para elegir el que menor error tiene. En la siguiente tabla se muestra para cada modelo, diferentes cálculos de error.

Comparación de Modelos

Variable de datos: Temperatura
 Número de observaciones = 3197
 Índice Inicial = 1,0
 Intervalo de Muestra = 1,0

Modelos

- (A) ARIMA(1,1,1)
- (B) ARIMA(2,1,0)

Periodo de Estimación

Modelo	RMSE	MAE	MAPE	ME	MPE
(A)	0,212418	0,052187	0,0187939	-0,000195981	-0,0000801957
(B)	0,212798	0,0549239	0,0197808	-0,000210026	-0,0000911854

Tabla 12: Comparación de modelos para la temperatura

Del estudio de la tabla 14 se puede determinar que el mejor modelo, y por tanto el que usaremos en la fase de predicción, es el definido por $Z_t \sim ARIMA(1,1,1)$, aunque la diferencia entre ambos modelos propuestos es a penas insignificante y podría usarse cualquiera de los dos.

5.3 Predicción

Una vez elegido el modelo, se desarrolla sustituyendo los parámetros necesarios.

$$\text{Temperatura} = Z_t \sim ARIMA(1,1,1)$$

$$\phi_1(B)\nabla Z_t = \theta_1(B)a_t$$

$$(1 - \phi_1 B)(1 - B)Z_t = (1 - \theta_1 B)a_t$$

$$(1 - (1 + \phi_1)B + \phi_1 B^2)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = (1 + \phi_1)Z_{t-1} - \phi_1 Z_{t-2} + a_t - \theta_1 a_{t-1}$$

$$Z_t = (1 + 0.723098)Z_{t-1} - 0.723098 Z_{t-2} + a_t - 0.541362 a_{t-1}$$

En este caso, no ha sido necesaria ninguna transformación para estabilizar la serie en varianza, por lo que Z_t será la previsión en el instante t de la serie original "Temperatura".

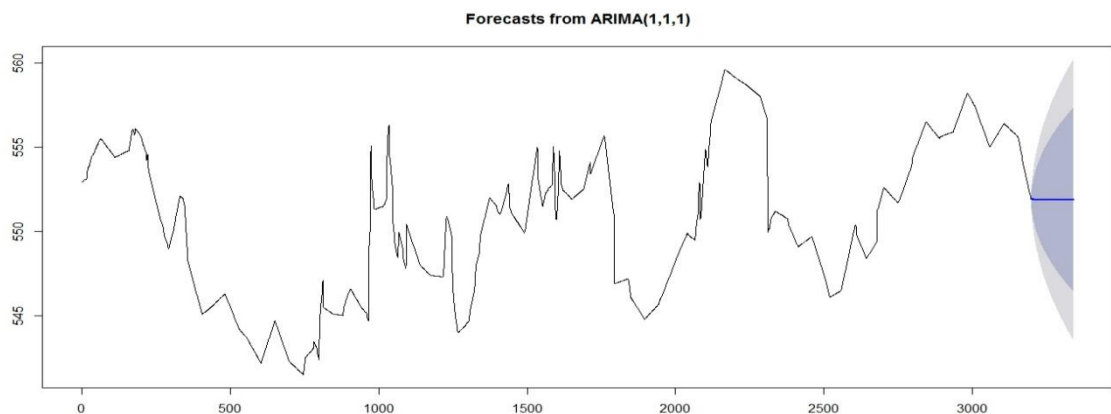


Figura 30: Predicción de temperatura ARIMA (1,1,1)

5.4 Densidad del aire

En un aerogenerador, la potencia de entrada se obtiene convirtiendo la fuerza del viento en un par actuando sobre las palas. La cantidad de energía transferida al rotor por el viento depende del área de barrido del rotor y de la velocidad del viento.

La energía cinética de un cuerpo en movimiento es proporcional a su masa. Así, la energía cinética del viento depende de la densidad del aire, es decir, de su masa por unidad de volumen, y de la velocidad del viento.

La densidad del aire depende fundamentalmente de dos factores, la presión y la temperatura, pudiéndose determinar dicha variación para una determinada altura mediante la fórmula de los gases ideales.

$$\rho = \frac{p(abs)}{R \cdot T (^{\circ}K)}, \quad \text{siendo } R = 287 \frac{Nm}{Kg ^{\circ}K}$$

A su vez, la presión y la temperatura dependen de la altura, puesto que a mayor altitud, menor es la temperatura (y mayor es la densidad del aire), mientras que la presión disminuye a medida que ascendemos en la atmósfera.

Debido a que en este trabajo se ha asumido que las mediciones se toman a la altura del rotor, la serie de temperatura no será necesario transformarla sea cual sea la altura de hipótesis.

Por otra parte, para el cálculo de la presión en función de la temperatura se tiene:

$$p = p_0 \exp \left[\frac{-g M (h - h_0)}{R T} \right]$$

Donde:

p_0 = presión estándar a nivel del mar: 101325 Pa

g = aceleración gravitacional: 9.80665 m/s²

M = masa molar del aire: 0.0289644 kg/mol

R = constante universal de los gases: 8.314472 J/ (°K·mol)

Suponiendo una altura de la torre de 80 metros, se tiene que la serie temporal de la presión sigue la siguiente forma:

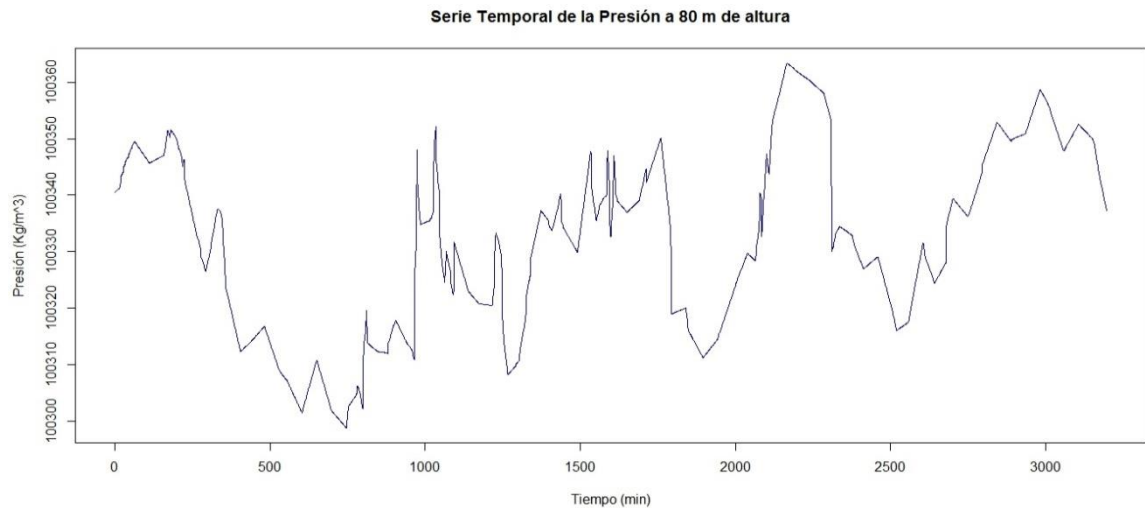


Figura 31: Serie temporal de la presión a 80 m de altura

Aplicando a continuación la fórmula de los gases ideales se tiene la serie temporal de la densidad del aire, la cual varía inversamente a la presión, puesto que ambos factores ya están teniendo en cuenta la variación de la temperatura y están medidas a la misma altura.

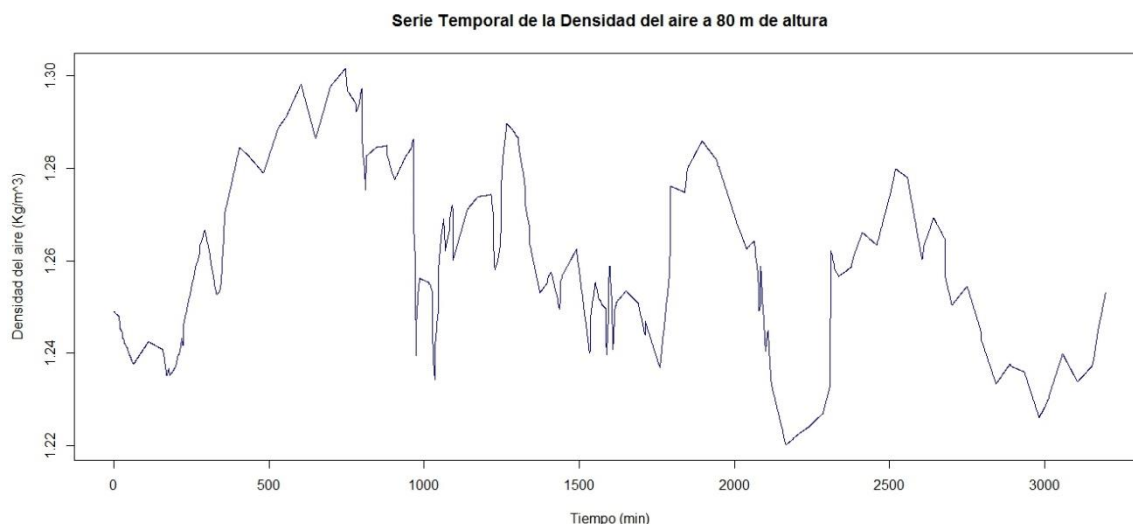


Figura 32: Serie temporal de la densidad del aire a 80 m de altura

Como se puede observar en la figura 32, la variación de la densidad del aire con la temperatura para una altura dada de 80 metros, se mueve entre un máximo $\rho_{max} = 1.301574 \frac{kg}{m^3}$ y un mínimo $\rho_{min} = 1.220174 \frac{kg}{m^3}$, lo cual apenas supone una variación real sobre la potencia generada.

Aplicando ahora el modelo de predicción definido para la temperatura y realizando la misma operación para el cálculo de la densidad del aire, se obtiene la siguiente serie.

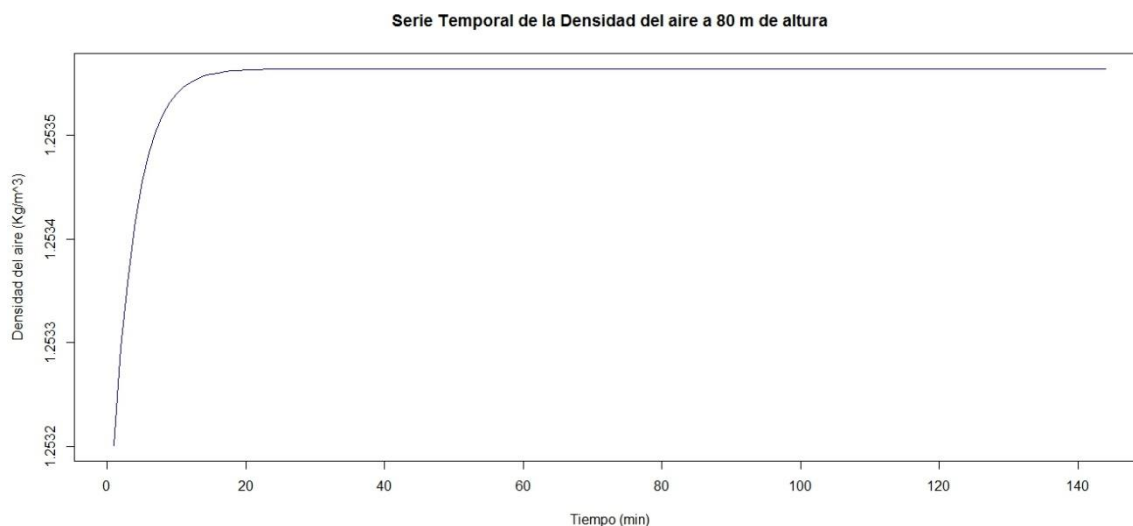


Figura 33: Predicción de densidad del aire a 80 m de altura

En el cálculo posterior de la potencia eólica, se asumirá la densidad:

$$\rho_{media} = 1.2536 \frac{kg}{m^3}.$$

6. ESTIMACIÓN DE LA POTENCIA ELÉCTRICA

6.1 Metodología

La previsión de la potencia eólica para cada hora puede obtenerse de diferentes maneras, siendo el objetivo de este apartado el comparar los resultados y determinar si existen diferencias significativas entre los métodos presentados.

En primer lugar, se puede tener una predicción directa de la potencia eólica a partir de datos de potencias anteriores. Este método es simple y efectivo si se disponen de los datos.

El segundo método propuesto para la comparación consiste en obtener la previsión a partir de la curva de potencia del aerogenerador en cuestión, la cual relaciona para cada velocidad de viento una potencia.

Otro método es obtener la potencia teórica a partir de los datos del aerogenerador, de velocidad de viento y densidad del aire.

Por último se contrastan todos los métodos anteriores con el resultado proporcionado por dos modelos de aerogeneradores comerciales.

6.2 Predicción de la serie temporal de potencia

6.2.1 Análisis descriptivo

Para predecir los valores futuros de la potencia eólica es necesario tener un modelo de predicción que se ajuste correctamente a la serie. Por tanto, se debe repetir la metodología para esta serie.

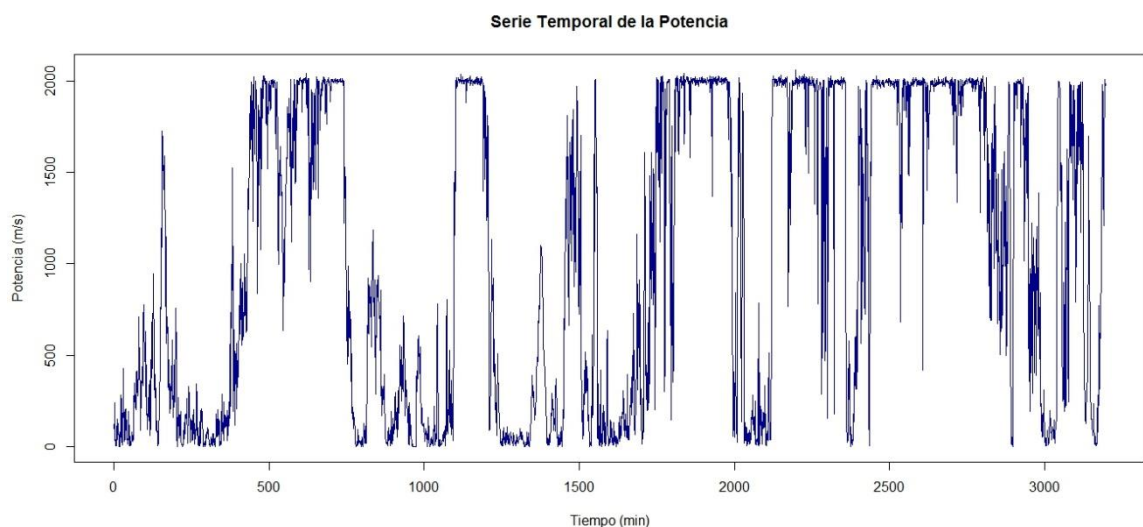


Figura 34: Serie temporal de la potencia eléctrica generada

Analizando la serie temporal de la potencia mostrada en la figura 34, se puede observar claramente que ésta se mueve entre dos límites, siendo la máxima potencia generada de 2000 kW.

En cuanto a los componentes para analizar, la serie tiene varianza y media aparentemente constante, lo cual se debe comprobar con el ACF y PACF.




Figura 35: Correlogramas de Potencia

Observando los correlogramas de la figura 35, se deduce que es necesario diferenciar la parte regular al menos una vez. Realizando un pronóstico automático mediante el programa estadístico “Statgraphics” se obtienen diferentes modelos tentativos ordenados por el criterio de mínimo AIC (tabla 15), los cuales no tienen por qué seguir la metodología Box-Jenkins.

Modelos

- (A) ARIMA(1,0,1)
- (B) ARIMA(2,0,1)
- (C) ARIMA(1,0,2)
- (D) ARIMA(2,0,2)
- (E) ARIMA(0,1,2)

Periodo de Estimación

Modelo	RMSE	MAE	MAPE	ME	MPE	AIC	HQC	SBIC
(A)	235,265	131,926	98,8206	11,9638	-76,6509	10,9227	10,924	10,9265
(B)	235,206	131,919	100,707	11,6563	-78,7847	10,9228	10,9248	10,9285
(C)	235,207	131,935	101,363	11,5741	-79,5085	10,9228	10,9249	10,9285
(D)	235,223	131,837	99,5342	11,7715	-77,5169	10,9236	10,9263	10,9312
(E)	235,599	129,543	102,764	0,862907	-81,8698	10,9255	10,9269	10,9293

Tabla 13: Comparación de modelos para la potencia

La tabla 15 muestra una gran similitud entre todos los modelos tentativos propuestos por el programa “Statgraphics” de manera automática, siendo el último de ellos el más diferente por ser el único modelo con diferencia regular.

Para contrastar nuestro análisis con los pronósticos automáticos, a continuación se analizan por separados el primero y el último.

6.2.2 ARIMA (1, 0, 1)

Haciendo el desarrollo de la ecuación del primer modelo tentativo:

$$Z_t \sim ARIMA(1,0,1)$$

$$\phi_1(B)Z_t = \theta_1(B)a_t$$

$$(1 - \phi_1 B)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = \phi_1 Z_{t-1} + a_t - \theta_1 a_{t-1}$$

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
AR(1)	0,992426	0,00227748	435,757	0,000000
MA(1)	0,291954	0,0171912	16,9827	0,000000

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 55349,8 con 3195 grados de libertad

Desviación estándar estimada de ruido blanco = 235,265

Número de iteraciones: 8

Tabla 14: Resumen de modelo de potencia ARIMA (1,0,1)

Una vez se tienen los valores de los parámetros del modelo, se comprueba si los residuos cumplen los requisitos para considerarse ruido blanco.




Figura 36: Análisis de la distribución normal de potencia del ARIMA (1,0,1)




Figura 37: Periodograma acumulado de potencia ARIMA (1,0,1)

Revisando las figuras 36 y 37 se verifica que el modelo recoge la suficiente información de la serie y cumple los requisitos necesarios para considerarse ruido blanco.

6.2.3 ARIMA (0, 1, 2)

Aplicando la misma metodología para el segundo modelo tentativo:

$$Z_t \sim ARIMA(0,1,2)$$

$$\nabla Z_t = \theta_2(B)a_t$$

$$(1 - B)Z_t = (1 - \theta_1 B - \theta_2 B^2)a_t$$

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
MA(1)	0,287005	0,0176839	16,2297	0,000000
MA(2)	0,0338364	0,0177198	1,90953	0,056193

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 55507,1 con 3194 grados de libertad

Desviación estándar estimada de ruido blanco = 235,599

Número de iteraciones: 2

Tabla 15: Resumen de modelo de potencia ARIMA (0,1,2)

Observando la significancia de los parámetros obtenidos en la tabla 17, se determina que el parámetro de orden dos de medias móviles no es significativo ($p\text{-value} > 0.05$) por lo que se puede eliminar.

Esto demuestra que no siempre los modelos automáticos generados por un programa como "Statgraphics" son del todo fiables y es necesario comprobarlos o seguir una metodología fija.

6.2.4 ARIMA (0, 1, 1)

Una vez descartado el segundo término de medias móviles, se descompone y analiza el modelo simplificado.

$$Z_t \sim ARIMA(0,1,1)$$

$$\nabla Z_t = \theta_1(B)a_t$$

$$(1 - B)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1}$$

Resumen de Modelo ARIMA

Parámetro	Estimado	Error Estd.	t	Valor-P
MA(1)	0,29417	0,0169878	17,3166	0,000000

Pronóstico Histórico: sí

Varianza estimada de ruido blanco = 55549,4 con 3195 grados de libertad

Desviación estándar estimada de ruido blanco = 235,689

Número de iteraciones: 2

Tabla 16: Resumen de modelo de potencia ARIMA (0,1,1)

Esta vez, el parámetro es totalmente significativo y por tanto se puede proceder a la comprobación de si los residuos se comportan como ruido blanco.

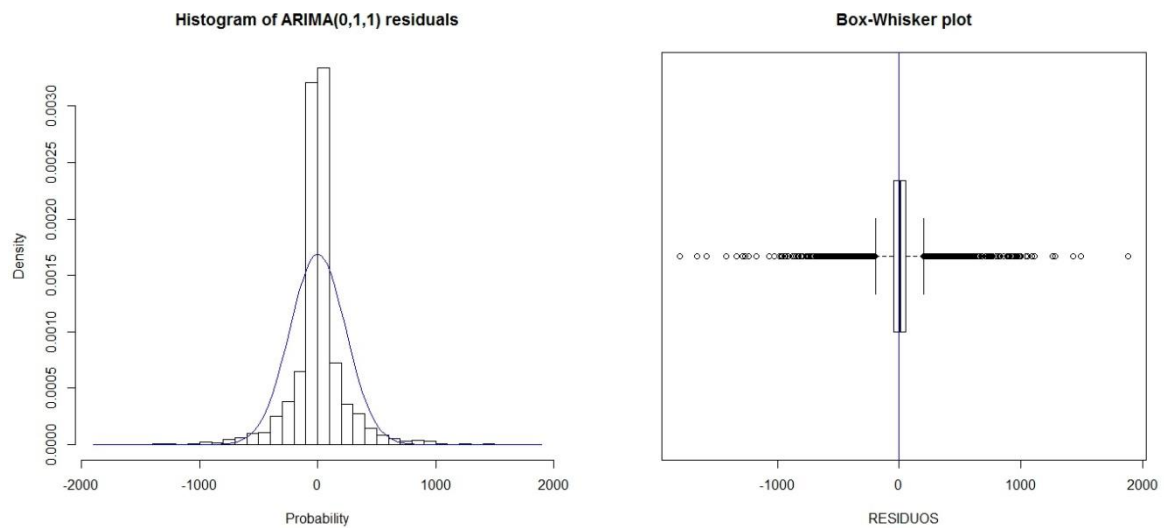


Figura 38: Análisis de la distribución normal de potencia del ARIMA (0,1,1)




Figura 39: Periodograma acumulado de potencia ARIMA (0,1,1)

Finalmente, se verifica que el residuo del modelo tentativo $Z_t \sim ARIMA(0,1,1)$ se comporta como ruido blanco y por tanto es un modelo viable para realizar un pronóstico.

6.2.5 Comparación de modelos

Tras haberse propuesto modelos tentativos, se comparan entre ellos para elegir el que menor error tiene. En la siguiente tabla se muestra para cada modelo, diferentes cálculos de error.

Modelos

- (A) ARIMA(1,0,1)
- (B) ARIMA(0,1,1)

Periodo de Estimación

Modelo	RMSE	MAE	MAPE	ME	MPE
(A)	235,265	131,926	98,8206	11,9638	-76,6509
(B)	235,689	129,409	100,023	0,831337	-78,8355

Tabla 17: Comparación de modelos ARIMA para la potencia

Analizando la tabla 19 se observa que dependiendo el error que se compare, un modelo es mejor que el otro y que ambos son muy similares, por lo que se elige el modelo que sigue la metodología de Box-Jenkins, en este caso $Z_t \sim ARIMA(0,1,1)$.

6.2.6 Previsión

Una vez elegido el modelo, se desarrolla sustituyendo los parámetros necesarios.

$$Potencia = Z_t \sim ARIMA(0,1,1)$$

$$\nabla Z_t = \theta_1(B)a_t$$

$$(1 - B)Z_t = (1 - \theta_1 B)a_t$$

$$Z_t = Z_{t-1} + a_t - \theta_1 a_{t-1}$$

$$Z_t = Z_{t-1} + a_t - 0.29417a_{t-1}$$




Figura 40: Predicción de potencia del ARIMA (0,1,1)

Con la fórmula desarrollada se obtiene la predicción para las siguientes 2 horas.

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
3198	1981.2	1679.1	2283.2	1519.23	2443.1
3199	1981.2	1612.0	2350.3	1416.65	2545.7
3200	1981.2	1555.4	2406.9	1330.03	2632.3
3201	1981.2	1505.5	2456.9	1253.66	2708.7
3202	1981.2	1460.3	2502.0	1184.57	2777.8
3203	1981.2	1418.7	2543.6	1121.02	2841.3
3204	1981.2	1380.1	2582.3	1061.84	2900.5
3205	1981.2	1343.7	2618.6	1006.26	2956.1
3206	1981.2	1309.3	2653.0	953.67	3008.7
3207	1981.2	1276.6	2685.7	903.65	3058.7
3208	1981.2	1245.4	2717.0	855.85	3106.5
3209	1981.2	1215.4	2746.9	810.00	3152.3

Tabla 18: Predicción de potencia en kW a partir del modelo ARIMA (0,1,1)

6.3 Predicción a través de la curva de potencia

Entre los métodos indirectos de obtención de la potencia eólica, es decir, aquellos que utilizan otros datos que no son directamente una serie temporal de potencias, se encuentra el método de la curva de potencia característica del aerogenerador.

Cada aerogenerador tiene asociada una curva de potencia que relaciona para cada velocidad de viento una potencia. En el caso que nos ocupa, debido a que no se tiene ningún dato del aerogenerador, lo primero que se debe sacar es esta relación.

Puesto que se tienen varias series que están relacionadas con la potencia, es necesario comprobar las distintas correlaciones.

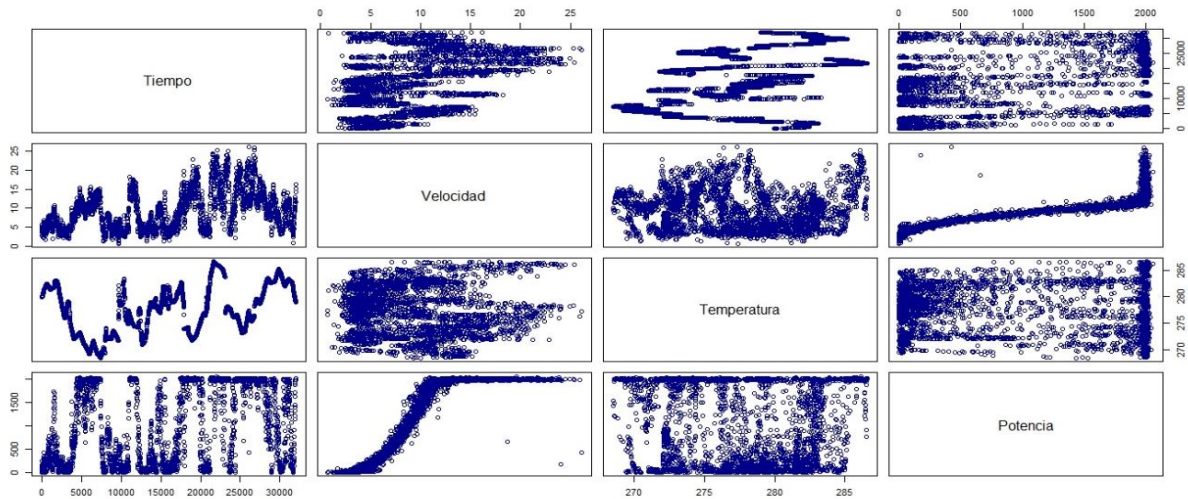


Figura 41: Relación entre variables

Si se analiza la figura 41 se contempla una clara relación entre la potencia y velocidad, mientras que con los demás factores la relación es más dispersa. Esta dependencia se observa en la siguiente tabla:

	Tiempo	Velocidad	Temperatura	Potencia
Tiempo	1.00000	0.38725	0.41773	0.34393
Velocidad	0.38725	1.00000	-0.03193	0.90269
Temperatura	0.41773	-0.03193	1.00000	-0.11761
Potencia	0.34393	0.90269	-0.11761	1.00000

Tabla 19: Correlación entre variables

Si se representa en detalle la correlación entre la potencia y la velocidad del viento se comprueba que ésta tiene la forma típica de la curva de potencia de un aerogenerador.




Figura 42: Correlación de potencia y velocidad

Para poder calcular la potencia para cada velocidad de viento a partir de la curva de potencia, primeramente se debe sacar la ecuación que sigue. Para esto, sabiendo que la curva de potencia se mantiene en cero hasta el valor de velocidad de arranque, y constante a la potencia máxima a partir de la velocidad nominal, habrá que hacer una regresión a la curva intermedia.

Predicción de energía eólica mediante métodos probabilísticos a partir de series temporales de viento y potencia

Para esto, se ha desarrollado una función en el programa estadístico “R” el cual ajusta una regresión del orden que se le indique a la curva intermedia.

En este caso, aplicando una regresión de orden 3 y limitando la curva hasta un valor de velocidad de 12 m/s, valor en el que ya se tiene la potencia nominal, se dispone la siguiente curva.




Figura 43: Regresión de la curva de potencia-velocidad

$$P = 473.7 - 320.15 \cdot V + 61.29 \cdot V^2 - 1.94 \cdot V^3$$

Aplicando a esta curva las condiciones de contorno necesarias, se obtiene la velocidad de arranque (V_a) y la velocidad nominal (V_n).

$$473.7 - 320.15 \cdot V_a + 61.29 \cdot V_a^2 - 1.94 \cdot V_a^3 = 0$$

$$473.7 - 320.15 \cdot V_n + 61.29 \cdot V_n^2 - 1.94 \cdot V_n^3 = 2000$$

Resolviendo las ecuaciones se saca que $V_a = 3 \frac{m}{s}$ y $V_n = 11.6 \frac{m}{s}$.

Una vez se tienen las velocidades de arranque y nominal, se puede definir la curva característica del aerogenerador como:

$$\text{Para } V < V_a \quad P = 0$$

$$\text{Para } V_a < V < V_n \quad P = 473.7 - 320.15 \cdot V + 61.29 \cdot V^2 - 1.94 \cdot V^3$$

$$\text{Para } V > V_n \quad P = 2000$$

Sustituyendo “V” por los valores de las predicciones de viento obtenidas anteriormente (tabla 20), se obtiene el pronóstico de potencia eléctrica para las siguientes dos horas.

		<i>Límite en 95,0%</i>	<i>Límite en 95,0%</i>
<i>Periodo</i>	<i>Pronóstico</i>	<i>Inferior</i>	<i>Superior</i>
3198,0	12,7098	8,52648	18,9456
3199,0	12,8999	8,04439	20,6861
3200,0	12,8999	7,63898	21,7839
3201,0	12,8999	7,28791	22,8333
3202,0	12,8999	6,97799	23,8474
3203,0	12,8999	6,7005	24,835
3204,0	12,8999	6,44932	25,8022
3205,0	12,8999	6,21998	26,7536
3206,0	12,8999	6,00908	27,6926
3207,0	12,8999	5,814	28,6218
3208,0	12,8999	5,63264	29,5433
3209,0	12,8999	5,46332	30,4589

Tabla 20: Predicción de velocidad de viento en m/s

Time Series:

Start = 3198

End = 3209

Frequency = 1

[1] 2000 2000 2000 2000 2000 2000 2000 2000 2000 2000 2000 2000 2000

Tabla 21: Predicción de potencia en kW a partir de la curva de potencia

Analizando los resultados mostrados en la tabla 22 se observa que al ser la predicción de la velocidad de viento mayor que la velocidad nominal del modelo y mucho menor que la velocidad de corte, la potencia será siempre la nominal, en este caso 2000 kW.

6.4 Cálculo de la potencia teórica

Otro método para comparar, es el cálculo de la potencia teórica a partir de la predicción de la velocidad del viento y la densidad del aire.

La potencia eólica disponible se define como:

$$P = \frac{1}{2} \rho A C_p V^3$$

Siendo “A” el área de barrido por las palas y “C_p” el coeficiente de potencia del aerogenerador.

Antes que nada se debe calcular el área de barrido o, lo que es equivalente, el diámetro de las palas y la curva del coeficiente de potencia para cada velocidad.

Para esto, ya que se dispone de las series de potencia, velocidad del viento y densidad del aire, se puede obtener el producto del área por el coeficiente de potencia y representarlo frente al tiempo.




Figura 44: Coeficiente de potencia

La figura 44 muestra la representación de los puntos que definen la curva del coeficiente de potencia del aerogenerador.

Conociendo que el coeficiente de potencia se define por partes de forma:

$$\text{Para } V < V_a \quad C_p = 0$$

$$\text{Para } V_a < V < V_n \quad C_p = C_{p,max} \left[1 - A \left(\frac{V_m}{V} - 1 \right)^2 - B \left(\frac{V_m}{V} - 1 \right)^3 \right]$$

$$\text{Para } V > V_n \quad C_p = \frac{C_{p,n} V_n^3}{V^3}$$

Siendo $V_a = 3 \frac{m}{s}$, $V_n = 11.6 \frac{m}{s}$ y V_m la velocidad media.

Por tanto, para calcular el área de barrido, se realiza una regresión de la curva del producto del área por el coeficiente de potencia, limitado por la velocidad nominal y la velocidad de arranque.

$$A \cdot C_p = -845 + 845.7 \cdot V - 52.2 \cdot V^2$$

Para obtener el máximo de la curva basta con tomar la derivada e igualar a cero, siendo la solución la velocidad media $V_m = 8.1 \frac{m}{s}$, la cual resulta el $(A \cdot C_{p,max}) = 2580.328 \text{ m}^2$.

Teniendo en cuenta que la ley de Betz⁵ define una potencia máxima recuperable y por tanto un $C_{p,max} = 0.593$, se puede calcular el diámetro mínimo de las palas como:

$$D_{min} = \sqrt{\frac{4 \cdot (A \cdot C_{p,max})}{\pi \cdot C_{p,Betz}}} = 74.4 \text{ m}$$

⁵ La ley de Betz formula que la máxima conversión de energía cinética en energía mecánica usando un aerogenerador es de 16/27 (el 59,3%).

Una vez se obtenido el D_{min} se debe ir a catálogo y elegir un diámetro comercial más grande. En este caso se ha decidido elegir un $D = 80 m$.

Teniendo el diámetro del aerogenerador se calcula el $C_{p,max} = \frac{(A \cdot C_{p,max})}{A} = 0.513$

El siguiente paso es calcular los coeficientes A y B para el cálculo del C_p . Para ello es necesario resolver el siguiente sistema de ecuaciones:

Para $V < V_a$ $C_p(V_a) = 0 \rightarrow 0 = \left[1 - A \left(\frac{V_m}{V_a} - 1 \right)^2 - B \left(\frac{V_m}{V_a} - 1 \right)^3 \right]$

Para $V_a < V < V_n$ $C_p(V_n) = C_{p,n} \rightarrow \frac{P_n}{\frac{1}{2} \rho A V^3} = C_{p,n} \left[1 - A \left(\frac{V_m}{V_a} - 1 \right)^2 - B \left(\frac{V_m}{V_a} - 1 \right)^3 \right]$

Dando como resultados $A = 1.91462$ y $B = -0.94538$ y la curva del coeficiente de potencia.




Figura 45: Curva del coeficiente de potencia completa

Finalmente, se calcula la potencia eólica para la predicción de la velocidad del viento (tabla 22) y de densidad del aire para las siguientes dos horas para un diámetro de aerogenerador de 80m.

```
> pot.teor(fcv$mean, 80)
[1] 1989.5 1989.5 1989.5 1989.5 1989.5 1989.5 1989.5 1989.5 1989.5 1989.5
[11] 1989.5 1989.5
```

Tabla 22: Predicción de potencia teórica

Analizando los resultados de la tabla 24 se comprueba que teniendo en cuenta la consideración de que no se trabaja en el punto de rendimiento máximo del aerogenerador, la previsión de la potencia eléctrica generada baja un poco pero sigue estando muy cerca del máximo de la máquina y de las otras predicciones.

6.5 Curvas de aerogeneradores comerciales

El objetivo final de cualquier cálculo de predicción para un parque eólico, se debe adecuar a las características reales de dicho parque, y eso implica, por tanto, que se deben tener en cuenta los datos reales de los aerogeneradores instalados.

En este apartado se ha decidido comparar y elegir un aerogenerador comercial y comprobar que potencia se obtendría según catálogo para las predicciones de velocidad de viento obtenidas.

Para ello, se ha elegido un catálogo de la empresa “Gamesa” para aerogeneradores de 2.0 MW, y resulta que tienen diferentes tipos dependiendo del tamaño del rotor.

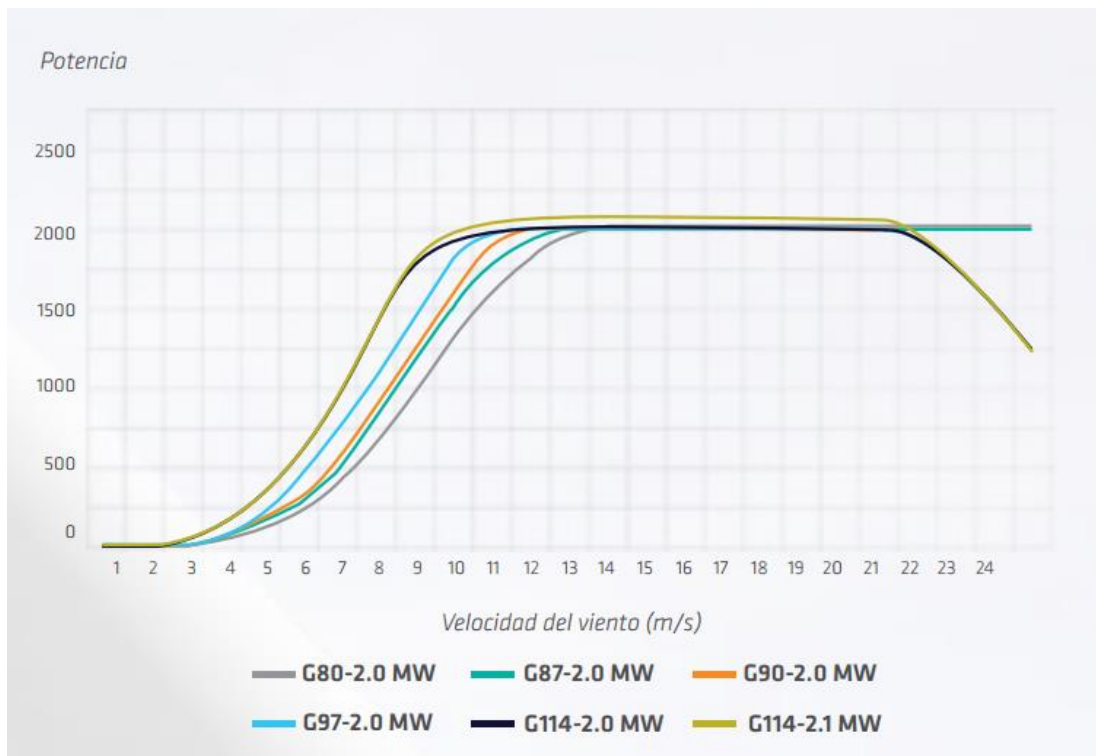


Figura 46: Curvas de Potencia para cada aerogenerador

Fuente: (Gamesa, 2017)

En la figura 46 se observan diferentes curvas de potencias para cada aerogenerador y se comprueba que aunque estén diseñadas para la misma potencia nominal (2.0 MW), cada una de ellas siguen una forma diferente y tienen velocidad de máximo rendimiento para diferentes velocidades de viento.

Esta figura es un primer indicativo de qué aerogenerador seleccionar, pues se debe buscar que la velocidad nominal $V_n = 11.6 \frac{m}{s}$ coincida aproximadamente con la entrada en la zona recta de la curva.

Para conocer en profundidad las características de cada aerogenerador, en la figura 47 se tiene un amplio resumen de todos estos tipos de aerogeneradores.

GAMESA 2.0 MW

	G80-2.0 MW	G87-2.0 MW	G90-2.0 MW	G97-2.0 MW	G114-2.0 MW	G114-2.1 MW
ROTOR						
Diámetro	80 m	87 m	90 m	97 m	114 m	114 m
Área de barrido	5.027 m ²	5.945 m ²	6.362 m ²	7.390 m ²	10.207 m ²	10.207 m ²
Velocidad de giro	9,0-19,0 rpm	9,0-19,0 rpm	9,0-19,0 rpm	9,6-17,8 rpm	7,8-14,8 rpm	7,8-14,8 rpm
PALAS						
Número de palas	3	3	3	3	3	3
Longitud	39 m	42,5 m	44 m	47,5 m	56 m	56 m
Perfil	NACA 63 XXX + FFA-W3	DU + FFA-W3	Gamesa	Gamesa	Gamesa	Gamesa
Material	Fibra de vidrio preimpregnado de resina epoxy	Fibra de vidrio preimpregnado de resina epoxy	Fibra de vidrio reforzada con resina de poliéster	Fibra de vidrio reforzada con resina de 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	Modular	Modular	Modular
Altura	60, 67, 78 y 100 m	78 y 90 m	55, 78 y 90 m	78, 90, 100, 104 y 120 m	80, 93, 125 m y según emplazamiento	80, 93, 106, 125, 153 m y según emplazamiento
MULTIPLICADORA						
Tipo	1 etapa planetaria 2 etapas de ejes paralelos	1 etapa planetaria 2 etapas de ejes paralelos	1 etapa planetaria 2 etapas de ejes paralelos	1 etapa planetaria 2 etapas de ejes paralelos	1 etapa planetaria 2 etapas de ejes paralelos	1 etapa planetaria 2 etapas de ejes paralelos
Ratio	1:100,5 (50 Hz) 1:120,5 (60 Hz)	1:100,5 (50 Hz) 1:120,5 (60 Hz)	1:100,5 (50 Hz) 1:120,5 (60 Hz)	1:106,8 (50 Hz) 1:127,1 (60 Hz)	1:128,5 (50 Hz) 1:102,5 (60 Hz)	1:128,5 (50 Hz) 1:102,5 (60 Hz)
GENERADOR						
Tipo	generador doblemente alimentado	generador doblemente alimentado	generador doblemente alimentado	generador doblemente alimentado	generador doblemente alimentado	generador doblemente alimentado
Potencia nominal	2.0 MW	2.0 MW	2.0 MW	2.0 MW	2.0 MW	2.1 MW
Tensión	690 V AC	690 V AC	690 V AC	690 V AC	690 V AC	690 V AC
Frecuencia	50 Hz/60 Hz	50 Hz/60 Hz	50 Hz/60 Hz	50 Hz/60 Hz	50 Hz/60 Hz	50 Hz/60 Hz
Clase de protección	IP 54	IP 54	IP 54	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*	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*

* Factor de potencia en bornas de salida del generador en el lado de baja tensión antes de la entrada del transformador.

Figura 47: Catálogo de aerogeneradores Gamesa

Fuente: (Gamesa, 2017)


Predicción de energía eólica mediante métodos probabilísticos a partir de series temporales de viento y potencia

Una vez visto el catálogo, y siguiendo con los resultados obtenidos en el apartado 6.4 donde se propone como diámetro del rotor 80 m, se analiza dicho aerogenerador en cuestión, viendo sus características particulares.

Power Curve Gamesa G80-2.0 MW (for an air density of 1.225 kg/m³)

Power curve calculation based on NACA 63.XXX and FFA-W3 air-foils.

Calculation parameters: 50 Hz grid frequency; tip angle pitch regulated; 10% turbulence intensity and a variable rotor speed ranging from 9.0 - 19.0 rpm.



Speed (m/s)	Power (kW)
4	66.3
5	152.0
6	280.0
7	457.0
8	690.0
9	978.0
10	1296.0
11	1598.0
12	1818.0
13	1935.0
14	1980.0
15	1995.0
16	1999.0
17	2000.0
18	2000.0
19-25	2000.0

Figura 48: Curva de Potencia Gamesa G80-2.0 MW

Fuente: (Gamesa, 2017)

En la figura 48 se muestra la curva real que sigue el aerogenerador Gamesa G80-2.0MW definida por tramos y sus respectivos valores. Con los valores dados en la tabla que definen la curva, es posible determinar la potencia real que se obtiene con este aerogenerador para la velocidad de viento pronosticada.

Dado que el pronóstico de la velocidad de viento obtenido en el apartado 4, se pueden interpolar los valores de la potencia eléctrica dada por el aerogenerador, los cuales se observan en la tabla 25.

Periodo	Velocidad (m/s)	Potencia (kW)
3198	12,7098	1901,047
3199	12,8999	1923,288
3200	12,8999	1923,288
3201	12,8999	1923,288
3202	12,8999	1923,288
3203	12,8999	1923,288
3204	12,8999	1923,288
3205	12,8999	1923,288
3206	12,8999	1923,288
3207	12,8999	1923,288
3208	12,8999	1923,288
3209	12,8999	1923,288

Tabla 23: Pronóstico Potencia Gamesa G80-2.0 MW

Viendo los resultados se puede decir que son próximos a los obtenidos anteriormente, sin embargo están por debajo de los tres métodos presentados previamente.


Dado los resultados anteriores y las curvas de los diferentes aerogeneradores (figura 46), se pasa a analizar el aerogenerador Gamesa G90-2.0 MW, puesto que su zona de entrada a potencia nominal se acerca más a la velocidad nominal obtenida.

Power Curve Gamesa G90-2.0 MW

(for an air density of 1.225 kg/m³)

Power curve calculation based on DU (Delft University) and FFAW3 airfoils.

Calculation parameters: 50 Hz grid frequency; tip angle pitch regulated; 10% turbulence intensity and a variable rotor speed ranging from 9.0-19.0 rpm.



SPEED (m/s)	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18-21
POWER (kW)	21.3	84.9	197.3	363.8	594.9	900.8	1,274.4	1,633.0	1,863.0	1,960.4	1,990.4	1,997.9	1,999.6	1,999.9	2,000.0	2,000.0

Figura 49: Curva de Potencia Gamesa G90-2.0 MW

Fuente: (Gamesa, 2017)

De forma análoga a lo visto con el aerogenerador Gamesa G80-2.0 MW, la figura 49 muestra la curva de potencia real y sus valores para el aerogenerador Gamesa G90-2.0 MW, con lo que volviendo a interpolar con los valores de predicción de viento se obtienen los siguientes valores de potencia:

Periodo	Velocidad (m/s)	Potencia (kW)
3198	12,7098	1981,694
3199	12,8999	1987,397
3200	12,8999	1987,397
3201	12,8999	1987,397
3202	12,8999	1987,397
3203	12,8999	1987,397
3204	12,8999	1987,397
3205	12,8999	1987,397
3206	12,8999	1987,397
3207	12,8999	1987,397
3208	12,8999	1987,397
3209	12,8999	1987,397

Tabla 24: Pronóstico Potencia Gamesa G90-2.0 MW

Una vez analizados los resultados de la tabla 24, se concluye que este aerogenerador presenta resultados más próximos a los obtenidos con los métodos anteriores, siendo muy similar a la predicción directa de la potencia y con el cálculo de la potencia teórica.

6.6 Comparación de métodos

Una vez desarrollado el pronóstico de la potencia eléctrica mediante diferentes métodos, es conveniente compararlos para saber cuán parecidos son entre ellos.

Así pues, en la tabla 27 se tiene un resumen de los diferentes métodos y sus pronósticos:

Periodo	Serie Temporal	Curva de Potencia	Potencia Teórica	G80-2.0 MW	G90-2.0 MW
3198	1981,2	2000	1989,5	1901,1	1981,7
3199	1981,2	2000	1989,5	1923,3	1987,4
3200	1981,2	2000	1989,5	1923,3	1987,4
3201	1981,2	2000	1989,5	1923,3	1987,4
3202	1981,2	2000	1989,5	1923,3	1987,4
3203	1981,2	2000	1989,5	1923,3	1987,4
3204	1981,2	2000	1989,5	1923,3	1987,4
3205	1981,2	2000	1989,5	1923,3	1987,4
3206	1981,2	2000	1989,5	1923,3	1987,4
3207	1981,2	2000	1989,5	1923,3	1987,4
3208	1981,2	2000	1989,5	1923,3	1987,4
3209	1981,2	2000	1989,5	1923,3	1987,4

Tabla 25: Resumen de pronósticos de potencia

En la tabla 27 se muestran los resultados obtenidos para cada periodo pronosticado por los diferentes métodos. En todos los casos la previsión da constante con el tiempo y con valor muy próximo a la potencia nominal.

En el análisis de los métodos de previsión, también es interesante saber el error cuadrático medio que existen entre los diferentes modelos. Cabe resaltar que este punto sería mucho mejor realizando el error con las medidas reales, pero al no existir éstas, el error entre los diferentes modelos nos explica qué parecidos son entre sí.

	Serie Temporal	Curva de Potencia	Potencia Teórica	G80-2.0 MW	G90-2.0 MW
Serie Temporal	-	18,80	8,30	60,06	5,94
Curva de Potencia	18,80	-	10,50	78,79	13,17
Potencia Teórica	8,30	10,5	-	68,33	3,02
G80-2.0 MW	60,06	78,79	68,33	-	65,63
G90-2.0 MW	5,94	13,17	3,02	65,63	-

Tabla 26: RMSE pronósticos de potencia

En la tabla 28 se muestra el RMSE⁶ de los métodos analizados, dando como resultado que el método que más se aleja de los demás es la curva de potencia real del aerogenerador Gamesa G80-2.0 MW. Esto implica simplemente que el aerogenerador no corresponde con el utilizado en el parque.

En cuanto a los otros métodos, se observa que todos son muy parecidos y sus RMSE son bajos. Esto determina que apenas existen diferencias entre ellos y que se pueden elegir cualquiera indistintamente.

⁶ RMSE: Error cuadrático medio o por sus siglas en inglés *Root Mean Square Error*, mide el promedio de los errores al cuadrado, es decir, la diferencia entre el estimador y lo que se estima.

7. CONCLUSIONES

Partiendo de la utilidad que presenta para el operador del sistema u otros agentes conocer con antelación suficiente la potencia eólica total que será generada, en este trabajo de final de grado se han propuesto diferentes modelos de predicción basados en series temporales de datos históricos.

Se han evaluado varios modelos de predicción para realizar una comparación entre los métodos directos e indirectos en un horizonte temporal a muy corto plazo que resulta útil en el ámbito de regulación del parque.

En general, los modelos obtenidos presentan poca variabilidad con el tiempo. Esto es debido a que están definidos bajo la hipótesis de permanencia constante del entorno, lo cual se considera cierto para horizontes temporales de muy corto plazo y funciona muy bien para procesos industriales. Sin embargo, debido a la gran inestabilidad e incertidumbre intrínseca que posee la meteorología, sería necesario hacer una comparación con métodos físicos o mixtos.

En cuanto a los resultados obtenidos, se verifica tal y como se cita en el artículo (ELSAM, 1996), que para cortos horizontes temporales no existen diferencias significativas entre los modelos directos e indirectos, es decir, aquellos que tienen en cuenta solo los datos históricos de la variable estudiada, y aquellos que obtienen el resultado a partir del análisis de otras variables relacionadas.

En este trabajo en cuestión, se comprueba que todos los métodos presentados obtienen resultados muy similares entre sí, lo cual corrobora además las previsiones de las series auxiliares y los cálculos realizados.

8. PRESUPESTO

A la hora de elaborar el presupuesto se han considerado los gastos derivados del estudio que se presenta en este proyecto. De acuerdo con las características del mismo, estos gastos pueden considerarse clasificados en las siguientes 3 categorías: personal, material y otros. A continuación se desglosan los costes asociados a cada uno de estos conceptos.

Costes de personal

En este apartado se incluyen los gastos relativos al personal que ha desarrollado el proyecto y las tareas realizadas. Así mismo, se ha considerado que el precio/hora para cualquiera de las tareas que se definen es de 25€/h, un precio estándar para un ingeniero que no dispone de mucha experiencia.

Para la realización del proyecto se distinguen tres tareas:

- Análisis estratégico: Estudio de las diferentes soluciones y metodologías más relevantes para los resultados finales.
- Validación y depuración de datos: Tiempo dedicado a la manipulación de los datos.
- Diseño de los modelos: Horas necesarias para la creación y diseño de los diferentes modelos de previsión.

Costes de material

Dentro de los costes de material o de equipos se consideran los costes de amortización de los equipos y software que se han empleado para llevar a cabo el proyecto. Se considerará el modelo de amortización lineal para la determinación del coste de amortización por cada hora. Los equipos empleados han sido:

- Uso de softwares: Coste de los programas usados para la realización del proyecto (*Statgraphics Centurios XVII*, paquete office, etc). El precio conjunto de paquetes es de 5000 €. Considerando una vida útil de 6000 horas con un coste de actualización del 10%, el coste unitario es de 0.9 €/h
- Equipo informático: Tiempo de equipo informático necesario para desarrollar las diferentes actividades. Teniendo en cuenta que se utiliza un ordenador portátil asus a53s valorado en 600 € con una vida útil estimada de 5 años, es decir, 43.800 horas, y considerando un coste de mantenimiento del 5% resulta una amortización de 0,017€/h.

Costes varios

Se han considerado un coste añadido del 7% (Artículo 9 de BOE-A-2016-5049) de la suma de los conceptos anteriores en concepto de gastos varios. Estos incluyen principalmente la electricidad consumida durante el tiempo que se ha desarrollado el proyecto.

Coste total

El total de los costes del proyecto se ha subdividido en dos partes. La primera de ellas incluyen todos los apartados anteriores: costes de personal, de material y otros, y se ha definido como "Subtotal". La otra parte del presupuesto corresponde a los impuestos indirectos, en particular al IVA, dando como resultado el presupuesto total.

A continuación se presenta una tabla resumen con el coste total del proyecto.

Categoría	Concepto	Cantidad	Coste unitario (€/h)	Total (€)
Personal	Análisis estratégico	35 h	25	875
	Validación y depuración de datos	20 h	25	500
	Diseño de modelos	245 h	25	6.125
Material	Uso de software	300 h	0.9	270
	Equipo informático	300 h	0.017	5,1
Otros	Costes indirectos	-	-	550,2
			Subtotal	8.325,3
Indirectos	IVA		21%	1.748,3
			Total	10.073,6

Tabla 27: Presupuesto total

9. BIBLIOGRAFÍA

- Acciona. (17 de Mayo de 2017). *Aerogeneradores*. Obtenido de Acciona: <https://www.acciona.com/es/energias-renovables/energia-eolica/aerogeneradores/>
- AEE. (17 de Abril de 2017). *Potencia instalada*. Obtenido de <https://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-espana/potencia-instalada/>
- Atmósfera Estándar Internacional*. (2017). Obtenido de Wikipedia: https://es.wikipedia.org/wiki/Atm%C3%B3sfera_Est%C3%A1ndar_Internacional
- CUCÓ PARDILOOS, S. (2017). *Manual de energía eólica: desarrollo de proyectos e instalaciones*. Valencia: Universitat Politècnica de València.
- ELSAM. (1996). *Final Report on EU JOULE II Project JOU-CT92-0083*. Brussels · Luxembourg: Official Publications of the European Communities.
- Fernández Jiménez, L. A. (2007). *Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos*. Universidad de La Rioja.
- Fukuda, H., Tamaki, S., Nakamura, M., Nagai, H., Shijo, F., S. Asato, & Onaga, K. (2001). *The Development of a Wind Velocity Prediction Method Based on a Data-Mining Type AutoRegressive Model*. Copenhagen, Denmark: Proceedings of the European Wind Energy Conference.
- Gamesa. (20 de Mayo de 2017). *Catálogo de plataformas*. Obtenido de <http://www.gamesacorp.com/recursos/doc/productos-servicios/aerogeneradores/nuevas-fichas/catalogo-plataformas.pdf>
- Gamesa. (20 de Mayo de 2017). *Gamesa G80-2.0 MW*. Obtenido de <http://www.wind-power-program.com/Library/Turbine%20leaflets/Gamesa/Gamesa%20G80%202mw.pdf>
- Gamesa. (23 de Mayo de 2017). *Gamesa G90-2.0 MW*. Obtenido de <http://www.wind-power-program.com/Library/Turbine%20leaflets/Gamesa/Gamesa%20G90%202mw.pdf>
- García Díaz, J. C. (2016). *Predicción en el dominio del tiempo. Análisis de series temporales para ingenieros*. Valencia: Universitat Politècnica de València.
- García Lobo, M. (2010). *Métodos de predicción de la generación agregada de energía eólica*. Madrid: Universidad Carlos III.
- Giebel, G., Richard Brownsword, R., & George Kariniotakis, A. (2003). *ANEMOS_D1.1_StateOfTheArt_v1.1.pdf*. ANEMOS.
- González, M. y. (2009). *Series temporales*. Servicio de publicaciones de la Universidad de Extremadura.

- GWEC. (25 de Abril de 2017). *Global Statistics*. Obtenido de <http://www.gwec.net/global-figures/graphs/>
- ICAO. (1993). *Manual of the ICAO Standard Atmosphere (extended to 80 kilometres (262 500 feet))*.
- IEA/IRENA Global Renewable Energy Policies and Measures Database © OECD/IEA and IRENA. (2015). *Energy Policies of IEA Countries. Spain 2015 Review*. IEA Publications.
- Ministerio de Empleo y Seguridad Social. (28 de Mayo de 2016). *BOE-A-2016-5049*. Obtenido de https://www.boe.es/diario_boe/txt.php?id=BOE-A-2016-5049
- Valdés, J. M., & Vinagre, C. (2012). *Modelos de Previsiones de Viento. Departamento de Ingeniería Eléctrica*. Chile: Pontificada Universidad Católica de Chile.
- Van der Hoeven, M. (2013). *Technology Roadmap. Wind energy*. IEA/IRENA Global Renewable Energy Policies and Measures Database © OECD/IEA and IRENA.
- Vithayasrichareon, S. M. (2017). *Getting wind and sun onto the grid. A manual for policy makers*. IEA/IRENA Global Renewable Energy Policies and Measures Database © OECD/IEA and IRENA.
- www.ree.es. (15 de 05 de 2017). *Estadísticas del Sistema Eléctrico*. Obtenido de REE: <http://www.ree.es/es/estadisticas-del-sistema-electrico-espanol/indicadores-nacionales/series-estadisticas>
- Zhu, X. a. (2012). *Short-term wind speed forecasting for power system operations*. Int. Stat. Rev. 80 2-23. MR2990340.