



## **RESIDENCIA PROFESIONAL**

**“ESTUDIO DE TÉCNICAS PARA EL PRONÓSTICO DE  
DISPONIBILIDAD DE ENERGÍA EÓLICA”.**

### **EMPRESA**

**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL  
INSTITUTO POLITÉCNICO NACIONAL.**

### **RESIDENTE**

**AGUILAR SOLÓRZANO LUIS ENRIQUE**

### **ASESOR INTERNO**

**DR. RAFAEL MOTA GRAJALES**

### **ASESOR EXTERNO**

**DR. JUAN MANUEL RAMÍREZ ARREDONDO**

**TUXTLA GUTIÉRREZ, CHIAPAS. DICIEMBRE 2014.**

<b>Contenido</b>	<b>Pág.</b>
<b>1. Introducción</b> .....	4
1.1 Antecedentes.....	4
1.2 Estado del arte.....	5
1.3 Justificación .....	6
1.4 Objetivo.....	6
1.4.1 Objetivos específicos .....	6
1.5 Metodología .....	7
<b>2. Fundamento teórico</b> .....	8
2.1 Viento como fuente de electricidad.....	8
2.2 Pronóstico de energía eólica .....	11
2.2.1 Aplicaciones del pronóstico de energía eólica .....	12
2.2.2 Horizontes de predicción.....	13
2.3 Métodos de pronóstico de velocidad y energía eólica .....	16
2.3.1 Enfoque físico .....	16
2.3.2 Enfoque estadístico.....	18
2.3.2.1. Enfoque estadístico convencional .....	18
2.3.2.2 Enfoque de redes neuronales artificiales.....	19
2.4 Series de tiempo.....	22
<b>3. Desarrollo</b> .....	23
3.1 Metodología de Box y Jenkins (ARIMA) .....	23
3.2 Casos de estudio .....	25
3.2.1 Caso de estudio Parque eólico Sotavento .....	25
3.2.1.1 Curva de potencia generador Gamesa G90 - 2.0 MW .....	29
3.2.2 Caso de estudio Estación meteorológica Chapala.....	29

3.2.2.1 Curva de potencia generador Skystream 3.7 - 2.4 kW .....	33
<b>4. Resultados y Conclusiones</b> .....	<b>33</b>
4.1 Resultados Sotavento.....	33
4.2 Resultados Estación meteorológica Chapala .....	37
4.3 Conclusiones .....	40
<b>Referencias Bibliográficas</b> .....	<b>41</b>
<b>Anexo A</b> .....	<b>44</b>
<b>Anexo B</b> .....	<b>45</b>

# 1. Introducción

## 1.1 Antecedentes

El continuo desarrollo industrial ha venido ligado a un aumento progresivo en el consumo de energía. Por otra parte, el aumento de la demanda de energía en los países desarrollados y en vías de desarrollo está acarreado una fuerte dependencia energética. La 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 que se adopten marcos regulatorios que favorecen el desarrollo y el uso de recursos energéticos renovables, limpios y sostenibles.

El impulso que se ha dado a las fuentes de energía de origen renovable ha propiciado un gran aumento de la potencia instalada, y entre ellas, la energía eólica ha sido la que ha tenido un mayor auge, debido principalmente al gran avance de la tecnología, resultando en un costo por megawatt instalado cada vez menor.

La ventaja de la energía eólica, que ha impulsado en mayor medida su desarrollo respecto de otras fuentes de energía renovables, es su elevada disponibilidad geográfica, pues en mayor o menor medida hay corrientes de viento en casi cualquier región del planeta. Así mismo, los sistemas eólicos no tienen costo de energía primaria, por lo cual los costos de operación y mantenimiento son bajos.

Sin embargo, un alto nivel de capacidad eólica instalada puede tener efectos negativos sobre el sistema eléctrico, que serán evidentes a medida que aumente el grado de penetración de estos sistemas en la red. La principal dificultad es que la energía eólica no puede ser programada y, por lo tanto, siempre hay incertidumbre sobre su producción, lo que puede disminuir la eficacia en la operación del sistema eléctrico.

Con el aumento de la penetración de generación eólica en los sistemas eléctricos interconectados, los operadores de sistemas se enfrentan a mayores niveles de variabilidad e incertidumbre. Teniendo en cuenta que la salida de energía de los parques eólicos está en función de la velocidad del viento, el nivel de generación varía dependiendo del día y la hora.

Los problemas causados por la naturaleza volátil de la velocidad del viento y su ocurrencia en las operaciones del sistema, tales como la programación y despacho de energía han llamado la atención de los operadores del sistema, los servicios públicos y los investigadores hacia los métodos de predicción de potencia eólica.

En México, el Centro Nacional de Control de Energía CENACE es el organismo encargado de realizar el despacho de energía eléctrica y determinar el nivel de generación de cada central. Así, cada central está sujeta a esta determinación y debe acatarla o informar de algún problema técnico o mantenimiento que impida alcanzar el nivel de generación solicitado.

Durante la operación normal de la red eléctrica, los operadores controlan los centros de generación y reparten las cargas con el objetivo de minimizar el costo de la generación eléctrica y maximizar la fiabilidad del sistema. Cada generador de energía se carga en función del costo del combustible, rapidez de arranque, disponibilidad y la velocidad de respuesta.

Por otra parte el operador de la red no tiene control sobre la disponibilidad y producción de los sistemas eólicos debido a la intermitencia de estos. A fin de satisfacer el despacho de energía, es necesario un método de pronóstico de la producción de energía eléctrica en parques eólicos en el corto plazo.

## **1.2 Estado del arte**

En 2014 A. Tascikaraoglu, M. Uzunoglu (Tascikaraoglu,2014) presentan una revisión y clasificación detallada métodos de pronóstico de velocidad del viento y potencia eólica para el corto plazo. Este documento describe los enfoques de pronósticos combinados y presenta una bibliografía actualizada de la literatura de pronóstico del viento. Por otra parte, el documento también señala las posibles direcciones de investigación adicionales de técnicas combinadas para ayudar a los investigadores en el campo de métodos de velocidad del viento y previsión de energía más eficaces.

En 2012 Gomes, P.; Castro, R. (Gomes,2012) en su trabajo abordan el tema del pronóstico de la energía eólica con dos modelos estadísticos, el auto-rregresivo de media móvil y redes neuronales artificiales. Presentan la teoría básica y la respectiva aplicación de estos modelos para realizar la predicción de energía eólica. Además, su capacidad de predicción se compara en tres estudios de casos diferentes. Al final, se extraen algunas conclusiones sobre el rendimiento de ambos modelos con respecto a sus capacidades de predicción, en comparación con modelos de referencia.

En 2012 Liu, H., Tian H. Q., & Li, Y. F. (Liu,2012) presentan un trabajo de comparación entre la metodología ARIMA y dos modelos híbridos, ARIMA-ANN y ARIMA-Kalman. La predicción se realiza para varios pasos por delante. Se demuestra que ambos modelos híbridos obtienen mejores resultados que el modelo ARIMA, siendo el modelo ARIMA-Kalman el mejor de los tres modelos obteniendo los menores índices de error. Las predicciones muestran ser adecuadas para horizontes de corto plazo.

En 2011 Jiménez Miguel (Jiménez,2011) presenta un trabajo comparando la metodología ARIMA (Autorregresive Integrated Moving Average) y las Redes Neuronales para el pronóstico de la velocidad del viento a corto plazo. Se demuestra que ambas técnicas trabajan de manera eficiente con series de tiempo en forma de velocidades del viento en el modelado de pronóstico a corto plazo.

En 2011 Sangita B, P.; Deshmukh, S.R. (Sangita,2011) utilizan Support Vector Machine (SVM) para la predicción de un día por delante de la velocidad del viento

a partir de datos históricos de la velocidad del viento en el sitio. Se observa que el porcentaje medio de error absoluto (MAPE) es de alrededor de 7% y el coeficiente de correlación es cercano a 1, lo que justifica la capacidad de SVM para la tarea de predicción de velocidad de viento.

En 2010 Soman, S.S.; Zareipour, H.; Malik, O.; Mandal, P. (Soman,2010) proporcionan información sobre las técnicas de predicción más importantes, relacionadas con la energía eólica y la velocidad del viento, sobre la base de la predicción numérica del tiempo (NWP), los enfoques estadísticos, redes neuronales artificiales (ANN) y técnicas híbridas a diferentes escalas de tiempo. Se discute también una visión general de análisis comparativo de diversas técnicas de predicción disponibles. Además, este trabajo enfatiza sobre los grandes retos y problemas asociados con la predicción de energía eólica.

En 2008 Fernández Luis en (Jiménez,2007) en su investigación muestra una recopilación de modelos para el pronóstico de energía eólica y algunas técnicas de optimización para estos modelos. Realiza una metodología en base al uso de modelos de Series Temporales y la implementación del Filtro de Kalman. Desarrolla un modelo de predicción con un horizonte de predicción de hasta 72 horas.

### **1.3 Justificación**

La energía eólica es una de las energías renovables de más rápido crecimiento, y es considerada como una alternativa atractiva a la energía convencional a partir de combustibles fósiles. A pesar de que la integración de energía eólica aporta muchas ventajas, una alta penetración de ésta proporciona desafíos en la operación y planificación del sistema de energía, debido principalmente a la incertidumbre y variabilidad del viento. En el sistema eléctrico, la energía suministrada debe ser igual a la demanda en todo momento. Sin embargo, la variación en la producción de energía eólica hace difícil mantener el equilibrio. Las predicciones de velocidad del viento y potencia son herramientas que permiten ayudar en la solución de algunas de las problemáticas que se mencionan, por lo cual desarrollar modelos eficaces y fiables se hacen necesarios para la reducción de costos de operación y mejorar la integración de la energía eólica en el sistema eléctrico existente.

### **1.4 Objetivo**

Implementar un modelo para la predicción a corto plazo de la producción eléctrica en parques eólicos utilizando la técnica estadística ARIMA, capaz de lograr predicciones confiables a partir de los datos disponibles.

#### **1.4.1 Objetivos específicos**

Revisar el estado del arte sobre técnicas de pronóstico de disponibilidad de la energía eólica.

Implementar distintas estructuras del modelo y seleccionar el más apto para el caso de predicción de potencia en parques eólicos.

## 1.5 Metodología

En la figura 1.1 se muestra el diagrama a bloques general del software. El primer paso es la selección del conjunto de datos que ingresara al modelo de predicción. El modelo de predicción realiza el algoritmo programado para obtener el pronóstico de velocidad del viento. Posteriormente los datos ingresan al modelo del generador, que permite estimar la potencia eólica de salida. Finalmente, se realiza la predicción de potencia eólica en Watts.

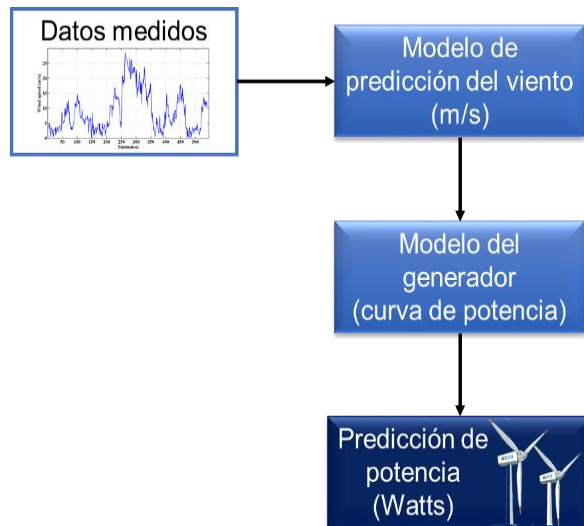


Figura 1.1 Diagrama a bloques software.

La figura 1.3 presenta el proceso del modelo de predicción. Se inicia con las mediciones de viento, obtenidas de una base de datos. Después, se verifica la estacionariedad de los datos examinando la función de autocorrelación y la función de autocorrelación parcial. Si la función de autocorrelación parcial decrece rápidamente, se dice que el proceso es estacionario. Sin embargo, si la función de autocorrelación decrece lentamente, se realiza la diferenciación de los datos para convertirlos en estacionarios. Se ilustra un ejemplo en la figura 1.2.

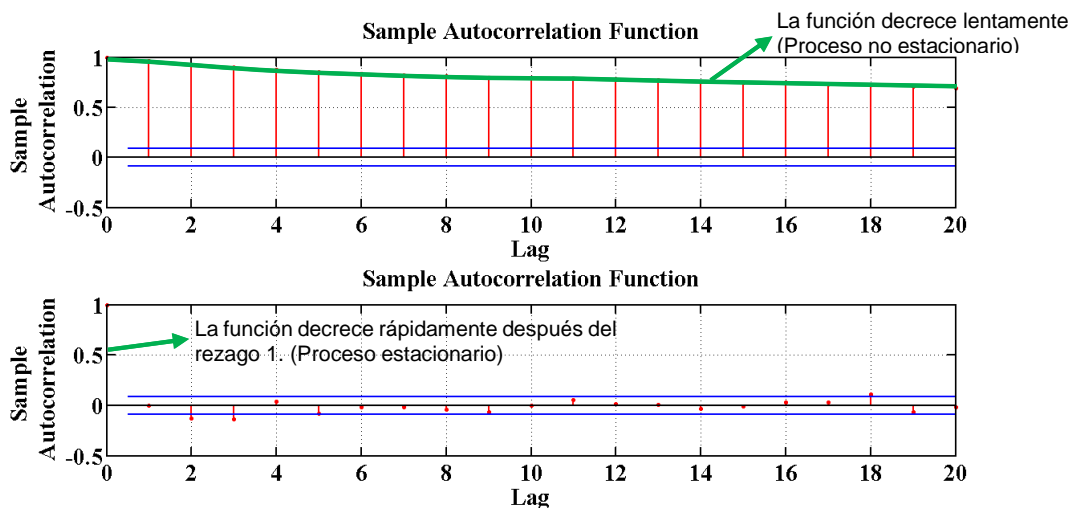


Figura 1.2 Decrecimiento autocorrelación parcial.

Posteriormente, se identifica el modelo y se estiman sus parámetros. Se realizan las pruebas y se verifica si el modelo se adapta. De lo contrario, se realiza nuevamente el proceso de identificación. Finalmente, se obtiene el pronóstico de velocidad del viento y se analiza la calidad de la predicción.

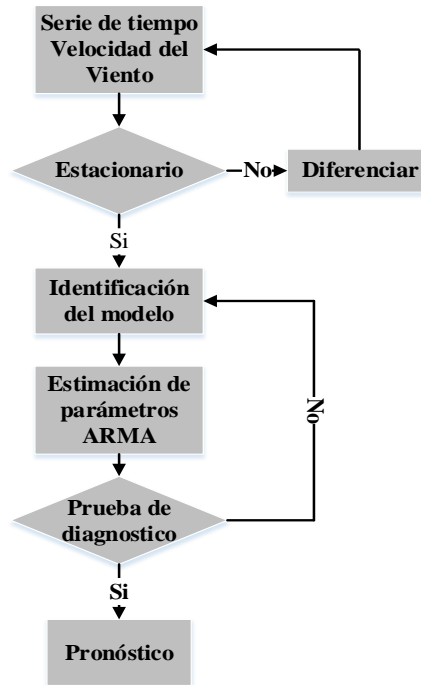


Figura 1.3 Diagrama modelo de predicción.

## 2. Fundamento teórico

En esta sección se investiga la historia y las perspectivas de la energía eólica y los principios físicos básicos que guían el uso del viento como fuente de energía. También se señalan algunos de los problemas y dificultades significativas relacionadas con la generación de energía eólica, especialmente en la venta a los mercados. Finalmente, se discuten las características del viento y la forma en que se transforma en energía.

### 2.1 Viento como fuente de electricidad

El viento es un recurso abundante de la naturaleza y una fuente intermitente de energía. La idea de utilizar el viento como fuente de energía es muy antigua, pero no llegó a ser económicamente sostenible, hasta la década de 1980. De acuerdo con (European,2009), en ese momento en California una combinación de créditos fiscales de inversión de energía estatales y federales ayudó a estimular un mercado en rápida expansión de la energía eólica. Durante el período comprendido entre 1980-1995, aproximadamente 1700 MW de capacidad de energía eólica fueron instalados. Esto fue posible gracias a un importante desarrollo en la tecnología de turbinas de viento. Después de esto Alemania, España, y Dinamarca experimentaron una gran expansión en el uso de este tipo de energía.



Las perspectivas de la energía eólica son muy alentadores en el futuro. El esfuerzo hacia formas de producción de electricidad más limpia ha creado un mercado siempre creciente para los fabricantes de turbinas eólicas. Lo mismo se aplica a los productores de los servicios auxiliares relacionados con la producción: el mantenimiento es un buen ejemplo. Los desafíos técnicos relacionados con la producción de energía eólica están lejos de resolverse. Ejemplos de ello son el uso de turbinas eólicas off-shore, donde los vientos soplan normalmente más fuerte, y también en las regiones árticas. El tamaño de las turbinas también está creciendo, en comparación con el estándar actual de 3-5 MW por molino de viento. Se estima en el futuro esto puede aumentar a 10 MW (European,2009). También hay una gran cantidad de investigación en relación con la utilización óptima y la gestión de los parques eólicos.

Dentro de todos los procesos de generación eléctrica, las características principales son las siguientes: independientemente de su tipo, se utiliza un combustible para hacer girar una turbina, que a su vez acciona un generador eléctrico para suministrar energía a la red. En energía eólica este combustible es, naturalmente, el viento. Sin embargo, hay una diferencia significativa entre la generación de electricidad convencional y la energía eólica. Esta última no es controlable por la intervención humana, sino que está dictada por los hechos meteorológicos presentes.

En consecuencia, un productor de energía eólica puede hacer poco para controlar el funcionamiento de las turbinas de viento alimentadas por este combustible intermitente. Sólo puede cambiar la producción por completo, y esto es raramente el tipo de acción deseada. El hecho es que ninguna cantidad de dinero o esfuerzo puede comprar viento adicional para una turbina de energía eólica, por no hablar de toda una granja. Del mismo modo, no se tiene la capacidad para programar la producción de cualquier otra manera.

Las turbinas de viento convierten la energía cinética en energía mecánica por un proceso de conversión. Idealmente, este proceso puede ser descrito por una curva de potencia característica de una turbina eólica. Una curva de este tipo es generalmente suministrada por el fabricante de aerogeneradores. La figura 2.1 ilustra un ejemplo de una curva de potencia. Se puede observar que debajo del llamado *cut-in speed* la potencia generada es cero. De igual forma, una turbina de viento siempre tiene además una *rated speed* (velocidad nominal), por encima de la cual la potencia de salida permanece constante.

La turbina no puede tomar infinita energía del viento, ya que cuando la potencia nominal de una turbina está a punto de ser superada, el control de la turbina garantiza que la potencia está limitada al valor nominal. Cuando los vientos fuertes están presentes la turbina se detiene a fin de evitar daños. Dependiendo de la turbina estos límites operacionales son por lo general en el orden de 2-4 m/s y 25-30 m/s, respectivamente.




Fig. 2.1 Curva de potencia turbina eólica

La curva de potencia de la turbina de viento puede ser teóricamente derivada de la siguiente manera. La energía cinética de una partícula con una masa  $m$  que se mueve a una velocidad  $w$ , se calcula mediante:

$$E = \frac{1}{2}mw^2 \quad (2.1)$$

Además, para la densidad de aire  $\rho$  y el volumen  $V$  la masa es:

$$m = \rho V \quad (2.2)$$

Asimismo,

$$\Delta V = Aw\Delta L \Leftrightarrow V = Aw \quad (2.3)$$

donde  $A$  es el área barrida por el rotor de la turbina eólica, y  $V$  es el volumen correspondiente al viento de la longitud  $L$ .

Insertando (2.3) en (2.2):

$$\dot{m} = \rho Aw \quad (2.4)$$

Finalmente, mediante la inserción de (2.4) en (2.1) la potencia ideal resulta:

$$\dot{E} = P = \frac{1}{2}\rho Aw \cdot w^2 = \frac{1}{2}\rho Aw^3 \quad (2.5)$$

En la ecuación (2.5) se nota que la energía eólica generada es esencialmente una función cúbica de la velocidad del viento. Esto explica el fuerte aumento entre la velocidad de corte y los límites de velocidad nominal vistos en la figura 2.1.

## **2.2 Pronóstico de energía eólica**

La electricidad generada a partir de energía eólica desempeñará un papel importante en el suministro de energía. Esto implica la necesidad de integrar esta energía dentro del sistema de suministro de energía eléctrica existente, el cual es diseñado principalmente para las grandes unidades de combustibles fósiles y las centrales nucleares.

La energía eólica tiene características diferentes, por lo tanto, esta integración conlleva algunos retos importantes desde el punto de vista del sistema eléctrico. La disponibilidad de la fuente de alimentación generada a partir de la energía eólica, varía respecto a la generada convencionalmente a partir de combustibles fósiles. La diferencia más importante es que la generación de energía eólica depende de la disponibilidad de viento.

En contraste con las plantas de energía convencionales, que son controladas para producir energía de acuerdo a la demanda, la energía eólica se produce por lo general de acuerdo con el viento disponible. Esto también significa que la salida de potencia fluctúa con las variaciones del viento.

En el sistema de electricidad, la oferta y la demanda deben ser iguales en todo momento. Por lo tanto, en un sistema eléctrico con una parte importante de energía eólica, se necesitan nuevos métodos para equilibrar la oferta y la demanda.

La previsión de la energía eólica tiene un papel clave en la lucha contra este desafío. Es el requisito previo para la integración de una gran parte de la energía eólica en un sistema eléctrico, ya que vincula la producción dependiente del clima con la producción programada de las centrales eléctricas convencionales y las previsiones de la demanda de electricidad, siendo este último predecible con una precisión razonable.

La figura 2.2 muestra la demanda de electricidad en Alemania durante una semana como un ejemplo (curva superior). El primer día es un día festivo, con una demanda relativamente baja de electricidad, en comparación con el cuarto día, que es un domingo. El sábado se muestra un ligero aumento de la demanda y también un curso temporal diferente. La carga es de nuevo un poco más alta el viernes entre las vacaciones y los fines de semana.




Figura 2.2 Demanda y energía eólica generada por una semana en Alemania (2003)

Los tres últimos días muestran las curvas de carga de lunes a viernes típicos. Esta curva de carga es fácilmente predecible, incluso para una semana con comportamiento atípico, como se muestra en el ejemplo. Las plantas de energía convencionales están programados de tal manera que su producción siga la curva de carga predicha.

Las desviaciones de la carga real prevista se igualan mediante el uso de la energía de equilibrio. La curva inferior que se muestra en la figura 2.2 fue la electricidad generada por la energía eólica en Alemania durante esta semana. Las plantas de energía convencionales tenían que suministrar sólo la parte de la carga que complementa a la curva inferior. El pronóstico de potencia de salida de energía eólica se utiliza, junto con la previsión de carga, para despachar las centrales eléctricas convencionales. De esta manera, sólo los errores en los pronósticos tienen que ser equilibrados por la energía de compensación. Esto también muestra claramente que el error de predicción determina la necesidad de equilibrar la energía con el fin de integrar la energía eólica.

Un pronóstico de la energía eólica es indispensable para el funcionamiento del sistema eléctrico y la seguridad del mismo. Su precisión radica en la necesidad de equilibrar la energía y, por lo tanto, el costo de la integración de la energía eólica. En consecuencia, grandes esfuerzos se han dirigido hacia el desarrollo de pronósticos de energía eólica de alta calidad y fiables durante los últimos años, y se han desarrollado muchos sistemas de previsión con diferentes enfoques. En países con una parte sustancial de energía eólica en el sistema eléctrico, como Dinamarca, Alemania o España, los sistemas de predicción de energía eólica son una parte esencial del control de la red y del sistema.

### 2.2.1 Aplicaciones del pronóstico de energía eólica

La aplicación más importante para el pronóstico de la energía eólica es reducir la necesidad de equilibrar la energía y la potencia de reserva, que son necesarias para integrar la energía eólica en la oferta y la demanda en el sistema de suministro de

energía eléctrica (es decir, para optimizar la programación de las centrales). Una segunda aplicación es proporcionar predicciones de energía eólica para la alimentación de la red y evaluar su seguridad. Para evaluar la seguridad de la red y para su operación (por ejemplo, para el mantenimiento y reparación), el operador de la red requiere conocer la energía eólica inyectada en ese momento, y el comportamiento de la energía eólica en cada punto de conexión a la red.

Las aplicaciones para la predicción de energía eólica pueden ser:

- Optimizar la programación de la central eléctrica y el equilibrio de potencia, requiere un pronóstico preciso de la generación de energía eólica para toda la zona de control. El horizonte de pronóstico depende del marco técnico y normativo.
- Para la determinación de la potencia de reserva que ha de requerirse para proporcionar la energía de equilibrio se necesita una predicción con gran exactitud. Los errores más grandes de pronóstico determinan la necesidad de energía de reserva, por lo cual estos tienen que ser minimizados.
- Para la operación de la red es necesaria la generación actual y pronóstico de energía eólica en cada punto de conexión a la red. Esto requiere de un pronóstico para pequeñas regiones o parques eólicos, incluso individuales. Para la gestión de la red, los horizontes de predicción más cortos son a menudo relevantes.

## **2.2.2 Horizontes de predicción**

El desarrollo de cualquier modelo de predicción debe contemplar, desde el primer momento de diseño, el horizonte de predicción, esto es, el periodo de tiempo (contabilizado desde un instante determinado en que realizamos la predicción), que determina el momento futuro para el que realizamos las predicciones. En otros problemas de predicción relacionados con el Sistema Eléctrico, como es el caso de la predicción de la demanda eléctrica, según el valor del horizonte la predicción puede clasificarse como de muy corto plazo, corto plazo, medio plazo y largo plazo.

Para el caso de la predicción de la potencia eléctrica producida en un parque eólico, no existe unanimidad en cuanto a las fronteras que separan una clasificación de otra. Es más, la mayoría de los autores rehúyen cuantificar los términos y los que si lo hacen dan valores diferentes, en especial para la predicción a muy corto plazo. El horizonte de predicción y el interés de la predicción para cada grupo es el indicado a continuación.

La tabla 1 muestra una clasificación resumida de los diferentes horizontes de predicción y también presenta las aplicaciones que estas tienen en la operación del sistema eléctrico.

- *Predicciones a muy corto plazo:* el horizonte de predicción es de unas horas, no existiendo unanimidad en su valor. Así, como valores extremos en (Usaloo,2004) se proponen cuatro horas y en (Mörhln,2004) se proponen nueve horas. Para un productor, las predicciones en este periodo son de interés con objeto de poder actuar en el mercado intradiario. Para el operador de la red eléctrica, estas predicciones son de interés para el mantenimiento de la seguridad del Sistema Eléctrico. Si se reduce el horizonte de predicción, también disminuyen los errores de predicción.
- *Predicciones a corto plazo:* el horizonte de predicción abarca desde el límite con el muy corto plazo hasta las 48 o 72 horas. En la mayoría de los trabajos publicados se limita a 48 horas, o incluso se limita a 36 horas. Esta predicción es la de mayor interés para poder actuar en el mercado diario eléctrico. Para el caso de España, dado que el plazo de presentación de ofertas de venta en el mercado diario se cierra a las 10 horas, un horizonte de predicción de 36 horas cubriría todo el día siguiente. En otros países el momento de cierre de recepción de ofertas puede diferir del caso de España, con lo que el número de horas de horizonte para cubrir las predicciones del siguiente día puede variar.  
Las predicciones de producción eléctrica correspondientes no al día siguiente, sino al posterior, actualmente carecen de interés económico en relación al mercado, ya que no se pueden realizar ofertas en el mercado eléctrico español. Sin embargo, son estas predicciones necesarias para aquellos parques eólicos que no venden la energía producida en el mercado eléctrico. Para los parques eólicos que venden la energía producida en el mercado, pueden resultar también interesantes, para poder programar labores de su mantenimiento durante las horas para las que las predicciones apuntan un valor muy bajo de potencia eléctrica generada.
- *Predicciones a más largo plazo:* corresponden a un horizonte por encima de las 48 o 72 horas llegando a un límite de 7 días. Cuanto mayor sea el horizonte, mayores son los errores de predicción, resultando al día de hoy difícil realizar predicciones fiables de variables atmosféricas por encima de esos 7 días. Estas predicciones (hasta 7 días) pueden ser de interés para la previsión del despacho de centrales eléctricas convencionales, y/o la programación de las labores de mantenimiento en algunas centrales (en la programación del sistema de generación), en periodos con previsiones de alto régimen de viento durante varios días, los parque eólicos pueden suministrar unos valores de potencia eléctrica media cercanos a su potencia instalada, posibilitando que otro tipo de centrales puedan reducir su generación eléctrica o programar labores de mantenimiento que podrían afectar a su producción.

La mayor parte de los trabajos publicados describiendo modelos de predicción se han centrado en la predicción de la producción eléctrica en un corto plazo, considerando éste con un horizonte de predicción entre 36 y 48 horas.

Tabla 1 Clasificación de escala de tiempo para diferentes técnicas de predicción. (Soman,2010)

HORIZONTE DE TIEMPO	RANGO	APLICACIONES
MUY CORTO PLAZO	Pocos segundos a 30 minutos por delante	Compensación del mercado eléctrico, acciones de regulación.
CORTO PLAZO	30 minutos a 6 horas por delante	Planificación del despacho económico de carga, decisiones de incremento/decremento de carga.
MEDIANO PLAZO	6 horas a 1 día por delante	Decisiones generador online/offline, seguridad operacional un día por delante del mercado eléctrico.
LARGO PLAZO	1 día a 1 semana o más por delante	Decisiones de compromiso de la unidad, decisiones de reserva, programación de mantenimiento para obtener el costo operación máquina.

Nota: Los límites de términos de pronóstico no están estrictamente definidos y puede haber una variación en función de la aplicación del pronóstico.

La figura 2.3 presenta la curva de potencia (potencia generada en función de la velocidad del viento, con condiciones de viento constante) para un aerogenerador de última generación. Como puede apreciarse, la mayor variación de potencia eléctrica generada está en el rango de velocidades de viento de 4 a 12 m/s, aproximadamente. Un ligero error en la predicción de la velocidad del viento por parte del modelo atmosférico puede significar un alto error de predicción en la potencia eléctrica generada.




Figura 2.3 Curva de potencia aerogenerador Gamesa G90- 2.0 MW.

Así, la predicción de la potencia eléctrica generada en el corto plazo por un parque eólico constituye una tarea difícil, no exenta de importantes errores. Pero a pesar de su dificultad, resulta ser actualmente imprescindible, tanto desde un punto de vista técnico como económico. Para proporcionar a los usuarios estas predicciones de producción eléctrica, se han elaborado en los últimos años modelos para la medida de la incertidumbre asociada a la de la predicción de la potencia eléctrica generada en parques eólicos.

### **2.3 Métodos de pronóstico de velocidad y energía eólica**

El papel básico de la velocidad del viento y la predicción de potencia es proporcionar información sobre la velocidad del viento y la potencia que se puede esperar en los próximos minutos, horas o días. Sobre la base de los requisitos de operación del sistema de potencia, el pronóstico puede ser dividido en cuatro horizontes diferentes: a muy corto plazo (unos pocos segundos a 30 min), a corto plazo (30 min a 6 h), a medio plazo (6-24 h), y a largo plazo (1-7 días) (Soman,2010).

Las predicciones a muy corto plazo se utilizan para el control de la turbina y el seguimiento de la carga. Las predicciones a corto plazo se utilizan para el intercambio de precarga. Las predicciones a medio plazo se utilizan para la gestión del sistema de energía y comercio de energía. Predicciones a largo plazo se utilizan para la programación del mantenimiento de las turbinas de viento.

La investigación en el área de la velocidad del viento y predicción de la energía producida por los parques eólicos se ha dedicado al desarrollo de herramientas eficaces y fiables, por lo cual muchos enfoques diferentes se han propuesto. Dos enfoques principales son el físico y el enfoque estadístico. En algunos modelos se combinan ambos enfoques en un intento de integrar las ventajas de ambos. En esta sección se presenta una visión general de los enfoques de la velocidad del viento y la predicción de energía existentes.

#### **2.3.1 Enfoque físico**

El enfoque físico para el pronóstico, en contraste con el enfoque estadístico, utiliza la descripción física detallada para modelar las condiciones de la ubicación del parque eólico (Kariniotakis,2004). El funcionamiento básico de un enfoque físico se ilustra en la figura 2.4. Lleva a cabo el refinamiento de los datos de la Predicción Numérica del Tiempo (NWP) para tener en cuenta las condiciones en el lugar por un método de reducción de escala, basado en la física de la capa inferior atmosférica.

El método de reducción de escala requiere la descripción física detallada de los parques eólicos y sus alrededores, incluyendo: descripción del parque eólico (diseño de parques eólicos y la curva de potencia de la turbina eólica) y la descripción del terreno (orografía, rugosidad, obstáculos, etc.). Si los datos de velocidad del viento se encuentran disponibles en línea, se realizan estadísticas de salida del modelo para reducir el error de la previsión.



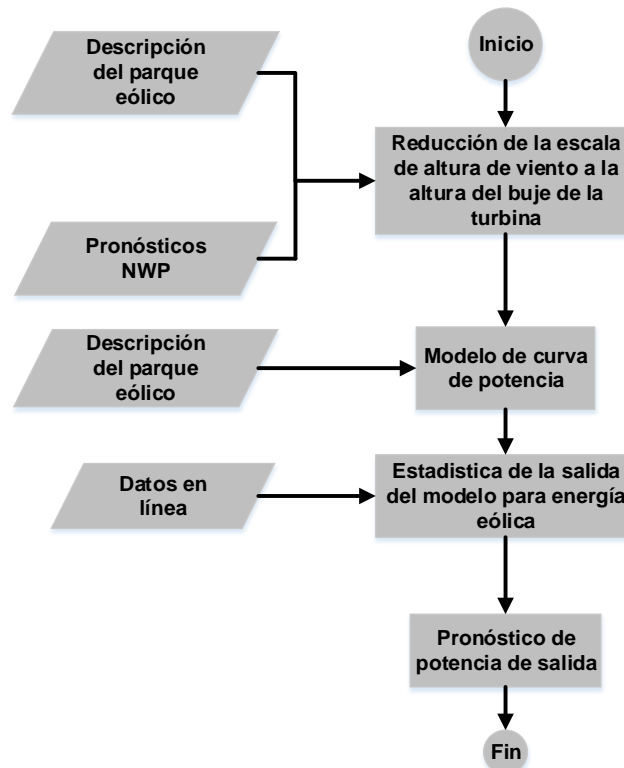


Figura 2.4 Enfoque físico para la predicción de velocidad del viento y potencia. (Jung,2014)

Contrario al enfoque estadístico, el enfoque físico no requiere entrada de entrenamiento a partir de datos históricos. Sin embargo, la adquisición de los datos físicos es uno de los principales inconvenientes de este enfoque. Una serie de enfoques físicos se han introducido en (Lei,2009), (Kariniotakis,2004), (Costa,2008). El Prediktor es sistema desarrollado por el Laboratorio Nacional Risoe en Dinamarca. Utiliza análisis de un Atlas de viento y programación de aplicaciones (WASP) y el programa Park toma las condiciones locales en cuenta mediante el uso de la predicción de NWP de alta resolución mediante el Modelo de área limitada (HIRLAM), (Landberg,2001).

El Previento, desarrollado por la Universidad de Oldenburg en Alemania tiene un enfoque físico similar, pero usa un pronóstico diferente de NWP conocido como Lakelmodell del Servicio Meteorológico Alemán (Focken,2001). El LocalPred es desarrollado por CENER (Centro Nacional de Energías Renovables) en España. Se trata de la optimización adaptativa de la previsión del NWP, el modelado de series temporales, la modelización meso-escala con MM5, y el modelado de la curva de potencia (Marti,2003). El eWind, desarrollada por AWS TrueWind Inc. en los EE.UU., tiene un enfoque físico similar con Prediktor pero utiliza un modelo de capa límite de alta resolución (ForeWind) como NWP para tomar las condiciones locales en cuenta (McGowin,2003).

Los enfoques físicos se basan en el uso de los principios físicos fundamentales para la conservación de la masa, cantidad de movimiento y energía en el flujo de aire. Estos modelos tratan la dinámica de fluidos computacional (CFD) para simular la

atmósfera. Aunque hay muchos modelos CFD disponibles, todos ellos están basados en los mismos principios físicos básicos. Se diferencian en cómo se estructuran y se escalan las rejillas, y cómo se realizan los cálculos numéricos.

### 2.3.2 Enfoque estadístico

La alternativa principal para la predicción de velocidad del viento y potencia se basa en modelos estadísticos. El enfoque estadístico representa la relación entre la energía eólica o la predicción de velocidad y las variables explicativas, incluidas NWP y datos de medición en línea (Kariniotakis,2004). La forma general del modelo se ilustra en la figura 2.5. El enfoque estadístico generalmente utiliza datos históricos para construir el modelo. Este modelo utiliza pronóstico NWP para el tiempo  $t+k$  y mediciones en línea en el tiempo  $t$  para pronosticar en las próximas horas.

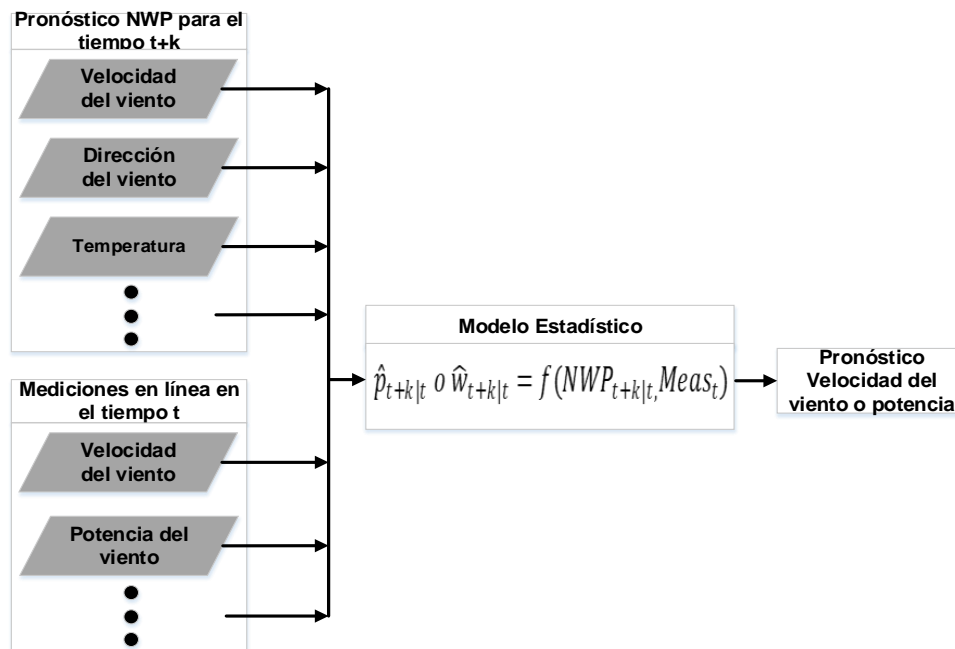


Figura 2.5 Enfoque estadístico para la predicción de velocidad del viento y potencia. (Jung,2014)

Sin embargo, a diferencia del enfoque físico, el enfoque estadístico requiere datos históricos para entrenar el modelo. Se emplean muchos enfoques diferentes (Soman,2010), (Lei,2009), (Foley,2012),(Dongmei,2011). Algunos de los enfoques estadísticos representativos son revisados en esta sección.

#### 2.3.2.1. Enfoque estadístico convencional

En el enfoque estadístico convencional se aplica un modelo de series de tiempo para pronosticar el valor futuro de la energía eólica o la velocidad del viento. De acuerdo con el proceso de predicción, que fue propuesto por Box y Jenkins, este modelo se divide en cuatro pasos principales para realizar un modelo matemático del problema. Existen varios tipos de modelos de series de tiempo, el modelo

autorregresivo (AR), modelo de medias móviles (MA), autorregresivo y de medias móviles (ARMA), y autorregresivo integrado de medias móviles (ARIMA). La forma general del modelo es como se muestra en (2.6),

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.6)$$

donde,  $X_t$  representa el pronóstico en el tiempo  $t$ ,  $\varphi_i$  es el parámetro autorregresivo,  $\theta_i$  es el parámetro de media móvil,  $c$  es la constante, y la variable  $\varepsilon_t$  es el ruido blanco.

Los enfoques estadísticos convencionales se basan en modelos estadísticos lineales clásicos como AR, MA, ARMA, y el enfoque de Box y Jenkins, se basa en ARIMA o modelos ARIMA ajustados estacionalmente, también conocidos como modelos SARIMA. Sin embargo, las referencias muestran que la precisión de predicción se puede mejorar en función de los parámetros del modelo que son seleccionados. Los métodos estadísticos convencionales están dirigidos en su mayoría al pronóstico de muy corto y corto plazo. Estos modelos son fáciles de formular y son capaces de proporcionar predicciones oportunas. Con la mejora de la precisión del pronóstico, los enfoques estadísticos convencionales se utilizan a menudo como un modelo de referencia.

### 2.3.2.2 Enfoque de redes neuronales artificiales

Otro enfoque son las redes neuronales artificiales (ANN). Los pronósticos de NWP y otras variables meteorológicas se transforman en las predicciones de energía eólica o velocidad del viento por ANN, que han sido entrenadas por los grandes conjuntos de datos históricos, con el fin de aprender la dependencia de la producción en las variables de entrada. El enfoque general de ANN para la velocidad del viento y predicción de potencia se muestra en la figura 2.6.

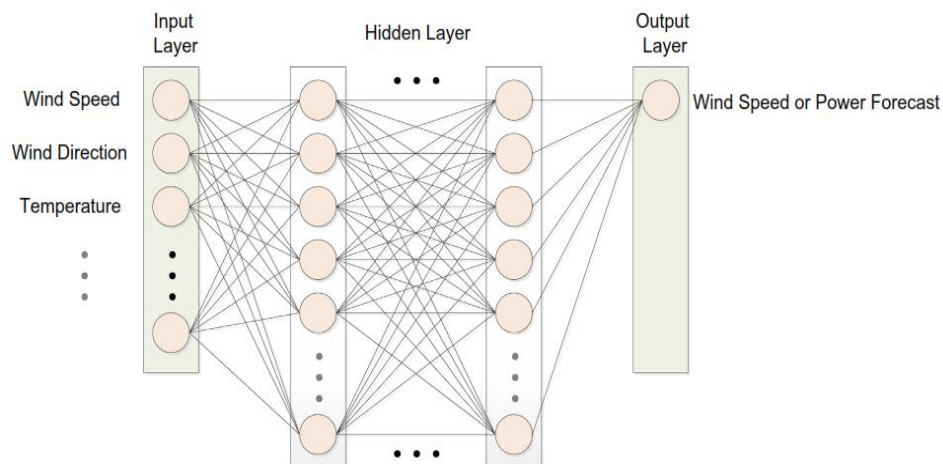


Figura 2.6 Enfoque ANN para la predicción de velocidad del viento y potencia.

ANN han sido un buen enfoque para la predicción de la velocidad del viento y potencia. ANN es capaz de modelar una relación no lineal compleja y extraer la dependencia entre la entrada y salida a través del proceso de aprendizaje. Es simple de construir y sólo requiere tiempos de desarrollo cortos, y no requiere de expresiones matemáticas explícitas. ANN puede diseñarse mediante la creación de la estructura de la red y después de seleccionar un algoritmo de aprendizaje.

Una visión general de los métodos de predicción de viento y potencia eólica, así como las fortalezas y debilidades de cada uno de los modelos reportados en la literatura se presentan en la tabla 2 y 3.

Tabla 2 Métodos de pronóstico velocidad del viento y potencia. (Soman,2010)

<b>Método de pronóstico</b>	<b>Subclase</b>	<b>Ejemplos</b>	<b>Observaciones</b>
<b>Método de persistencia</b>	-	$P(t+k)=P(t)$	-Enfoque Benchmark -Muy preciso para muy corto y corto plazo
<b>Enfoque físico</b>	Predicción numérica de tiempo (NWP)	-Sistema de pronóstico global -MM5 -Prediktor -HIRLAM, etc.	-Uso de datos meteorológicos, como la velocidad y dirección del viento, presión, temperatura, humedad, estructura del terreno, etc. -Precisa para largo plazo
<b>Enfoque estadístico</b>	Redes Neuronales Artificiales (ANN)	-Feed-forward -Recurrente -Perceptrón multicapa -Funciones de base radial Adaline, etc.	-Precisión a corto plazo -Estructura híbridas útiles para mediano y largo plazo -Por lo general superan a los modelos de series de tiempo
	Modelos de series de tiempo	-ARX -ARMA -ARIMA -Predictores grises -Predicciones lineales -Suavizado exponencial, etc.	-Preciso para corto plazo -Algunos muy buenos modelos de series temporales reemplazan estructuras ANN
<b>Algunas técnicas nuevas</b>	-	-Correlación espacial -Lógica difusa -Transformada de Wavelet -Predicciones por conjuntos Formación basada en entropía, etc.	-Correlación espacial es buena para corto plazo -Modelos basados en formación entropía mejora el rendimiento

<b>Estructuras híbridas</b>	-	-NWP + ANN -ANN + Fuzzy logic= ANFIS -Correlación especial + ANN -NWP + series de tiempo	-ANFIS es muy buena para pronóstico a muy corto plazo -Estructuras NWP + ANN son muy precisas para pronósticos de mediano y largo plazo
-----------------------------	---	---	--

Tabla 3 Breve comparación de los principales métodos utilizados para la predicción de la velocidad del viento y potencia en la literatura. (Tascikaraoglu,2014)

<b>Velocidad del viento/Potencia Método de pronóstico</b>	<b>Ventajas</b>	<b>Desventajas</b>
<b>Modelos NWP</b>	Aplicable para horizontes más largos de predicción	La debilidad en el manejo de los fenómenos de menor escala, no apto para los tiempos cortos de pronóstico, requiere grandes recursos y tiempo de cálculo
<b>Modelos de series de tiempo (AR, ARMA, ARIMA, f-ARIMA, etc.)</b>	Fácil de encontrar herramientas, estructura relativamente básica, capacidad de corrección de las tendencias locales en los datos, proporcionan las condiciones de intervalos de confianza para las predicciones	Requiere una gran cantidad de registros históricos, difícil de modelar problemas no lineales y decidir la mejor estructura
<b>Modelos basados en ANN</b>	Las ganancias de conocimiento a partir de datos de entrenamiento, no hay necesidad de especificar cualquier modelo matemático a priori, la tolerancia de error de datos alta, mayor capacidad de adaptación a las mediciones en línea	Requiere un procedimiento de entrenamiento y un gran número de datos de entrenamiento
<b>Modelos basados en SVM</b>	Alto rendimiento de generalización	Depende de la sintonización de los parámetros apropiadamente, optimización de procesos complejos y mayor tiempo de entrenamiento
<b>Lógica difusa</b>	Conveniente para los sistemas que son difíciles de modelar exactamente, relativamente menos complejo	De alta complejidad y un tiempo de proceso largo en el caso de muchas reglas

<b>Redes Bayesianas</b>	Capacidad para manejar observaciones faltantes y evitar el exceso de ajuste de los datos, adecuado para pequeños conjuntos de datos de entrenamiento, adecuado para varios datos de entrada	Requiere relativamente más esfuerzo, depende del nivel de experiencia del usuario
<b>Modelos filtro de Kalman</b>	No requiere de almacenar los datos históricos a causa de su forma recursiva	Requiere conocimientos previos sobre el sistema

## 2.4 Series de tiempo

Una serie de tiempo (también conocida como serie histórica, cronológica o temporal) es un conjunto de valores, correspondientes a una variable, ordenados según el instante en que fueron tomados, y normalmente tomados a intervalos de tiempo regulares. Los valores sucesivos contenidos en una serie de tiempo se designan por un número de índice, correspondiente al número de observación (número del instante en que fue tomado el valor). Así, suponiendo una serie de tiempo  $X$ , esta vendría expresada como indica la ecuación (2.7):

$$X = \{X_1, X_2, X_3, \dots\} \quad (2.7)$$

La predicción del valor futuro de una serie de tiempo significa determinar los siguientes valores que tomará la variable que forma la serie, a partir del instante presente. Esa determinación del valor futuro de la variable puede realizarse desde dos perspectivas indicadas a continuación.

1. La predicción de valores futuros se puede realizar por extrapolación de los valores pasados.
2. Se puede establecer un modelo matemático que explique las relaciones entre los valores de la variable en el pasado y utilizar ese modelo para predecir los futuros valores de la variable.

En muchas ocasiones se dispone de otras informaciones que pueden ser útiles en la determinación de los valores futuros de una variable, de la que se dispone de una serie de tiempo. La variable que se trata de predecir puede ser función de otras variables cuyos valores podemos conocer, lo que las hace variables explicativas de la variable a predecir. En función de que usemos, o no, esa información con los valores de las posibles variables explicativas, podemos distinguir dos métodos para establecer los valores futuros de la variable a predecir señalados a continuación.

- Métodos de predicción univariante (también conocidos como métodos de series de tiempo): estos métodos establecen la relación entre los propios valores pasados de la variable a predecir. Una vez establecida la relación,

con el modelo se realizan proyecciones hacia el futuro para obtener predicciones de la variable. Matemáticamente, el valor en un futuro inmediato de la variable a predecir es una función de sus valores pasados, como indica (2.8),

$$X_{t+1} = f(X_t, X_{t-1}, \dots, X_{t-d}) \quad (2.8)$$

- Métodos de predicción multivariante (también conocidos como métodos causales): estos métodos pretenden establecer la relación entre los valores pasados de la variable a predecir y los valores, también pasados, de las posibles variables explicativas. Una vez establecida la relación (determinado el modelo) puede ser utilizada para obtener valores futuros de la variable a predecir. La ecuación (2.9) expresa el valor futuro de la variable a predecir como una función de los valores futuros de otras dos variables (valores futuros, pero conocidos de antemano),  $u$  y  $v$ .

$$X_{t+1} = f(u_{t+1}, v_{t+1}) \quad (2.9)$$

### 3. Desarrollo

#### 3.1 Metodología de Box y Jenkins (ARIMA)

Box y Jenkins presentaron este modelo en (Box,1976), el cual es llamado autorregresivo de medias móviles. El modelo puede predecir valores futuros de variables de series de tiempo, mediante la regresión lineal de un conjunto de observaciones consecutivas de estas. La forma general del modelo es ARMA (p, q). De tal forma que  $p$  es el orden de la parte autorregresiva, que indica el número de variables rezagadas en la relación, y  $q$  es el orden de la media móvil,

$$y_t = \mu_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \phi_j e_{t-j} + e_t \quad (3.1)$$

donde,  $\mu_0$  es el termino constante (media del proceso estocástico),  $\phi_i$  es el  $i$ -ésimo parámetro autoregresivo,  $\phi_j$  es el  $j$ -ésimo parámetro de media móvil,  $e_t$  es el término de error en el tiempo  $t$ , y  $y_t$  es el valor de la velocidad del viento observado en  $t$  (Shi,2011).

Si la serie de tiempo alcanza la media constante durante cualquier intervalo de tiempo, y el factor de autocorrelación disminuye rápidamente, entonces el modelo ARMA (p,q) será el adecuado. De otra manera, se necesita transformar los valores de la serie temporal para volverla estacionaria. Esto se logra mediante la diferenciación de la serie de tiempo que resulta en una nueva parte en el modelo.

Así que la nueva forma del modelo será ARIMA (p,d,q) donde el orden d es el número de veces que se requiere diferenciar la serie. (Abdelaziz,2013)

Así, la serie de tiempo será diferenciada mediante (3.2), para lograr la estacionariedad. De tal manera que  $y_t$  es la serie temporal original y  $\Delta y_t$  es la nueva serie de tiempo diferenciada (d=1), ya que fue diferenciada una sola vez. Los valores más comunes de diferenciación necesaria para lograr la estacionariedad de la serie temporal son d=1, 2.

$$\Delta y_t = y_t - y_{t-1} \quad (3.2)$$

La metodología para determinar el modelo ARIMA (p,d,q) es mostrada en la figura 1.2 en el capítulo 2, la cual consiste de 4 pasos que se describen a continuación.

### Identificación

El primer paso es determinar el orden ARIMA (p,d,q). El orden p y q son determinados a partir de la verificación de la ACF (función de autocorrelación) y PACF (función de autocorrelación parcial). Una vez obtenidos los correlogramas, se siguen algunos criterios para conocer el modelo aproximado para adaptarse a cualquier AR (p), MA (q) o ARMA (p,q). El comportamiento de la ACF y PACF para series de tiempo estacionarias son resumidos en la tabla 4.

Tabla 4 Comportamiento teórico de la ACF y PACF para un proceso estacionario. (Montgomery,2011)

Modelo	ACF	PACF
MA (q)	Corta después del rezago q	Decaimiento exponencial y/o amortiguado senoide
AR (p)	Decaimiento exponencial y/o amortiguado senoide	Corta después del rezago p
ARMA (p,q)	Decaimiento exponencial y/o amortiguado senoide	Decaimiento exponencial y/o amortiguado senoide

### Estimación y diagnostico

Para la estimación de los parámetros de procesos autorregresivos AR (p), de medias móviles MA (q), o autorregresivos y de medias móviles ARMA (p, q) se requiere que la serie de N elementos (t=1,..., N) sea estacionaria. Los parámetros se estiman a través de un proceso de mínimos cuadrados no lineales.

### Predicción

La última fase consta de usar los modelos para realizar el pronóstico del siguiente valor, ya sea este un paso por delante, tres pasos por delante, etc. Para evaluar el mejor modelo se usan medidas estadísticas como el MSE, RMSE, MAE y MAPE, ecuaciones (3.3)-(3.6).



$$MAE = \frac{1}{N} \sum_{t=1}^N |y'_t - y_t| \quad (3.3)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left( \frac{|y'_t - y_t|}{y_t} \right) \quad (3.4)$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (y'_t - y_t)^2 \quad (3.5)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (y'_t - y_t)^2}{N}} \quad (3.6)$$

### 3.2 Casos de estudio

Para el desarrollo de los casos de estudio se utilizan datos procedentes del parque eólico de Sotavento que se encuentra ubicado en Galicia, así como los datos recabados de la estación meteorológica de Chapala ubicada en el estado de Jalisco.

Para ambos casos el estudio consiste en predecir la velocidad del viento a partir de un conjunto de 540 muestras anteriores, tomadas en intervalos de 10 minutos, las cuales son utilizadas para determinar un modelo de pronóstico, es decir, el orden  $p$ ,  $q$  y  $d$ . Después de identificar en forma tentativa un modelo que describa la serie temporal, se tienen que estimar los parámetros  $\varphi$ ,  $\Phi$ ,  $\mu_0$  y  $e_t$ .

Posteriormente el modelo es utilizado para la predicción de velocidad del viento en el siguiente instante de tiempo, en este caso 10 minutos. Con estas predicciones se consigue un día completo de pronóstico (144 muestras). La predicción es comparada con las mediciones de velocidad del viento real, y así se calculan los índices de error que se presenta la predicción.

#### 3.2.1 Caso de estudio Parque eólico Sotavento

Los datos utilizados en el trabajo son una serie de tiempo de velocidad del viento, con un periodo de muestreo de 10 minutos, registrados entre enero y diciembre de 2011 del Parque eólico experimental Sotavento Galicia. La figura 3.1 muestra la serie de velocidad del viento (540 muestras). Como puede observarse en la figura mencionada, la serie temporal es no estacionaria, debido a que presenta una tendencia en aumento, y no se aprecia que los valores presenten una media constante a través del tiempo.

En la figura 3.2 se observa que la función de autocorrelación (ACF), decrece lentamente, con lo cual se confirma que la serie temporal es no estacionaria. El eje de las abscisas ilustra el número de datos rezagados, para este caso 20, y el eje de las ordenadas muestra la correlación de los datos. La serie temporal se puede

transformar en estacionaria obteniendo las primeras diferencias de los valores de la serie temporal no estacionaria.




Fig. 3.1 Serie original velocidad del viento.




Fig. 3.2 Resultados de la ACF y PACF.

Se adopta la metodología de Box-Jenkins para determinar un modelo ARIMA en este trabajo. El enfoque parte del hecho de que la serie temporal que se trata de predecir es generada por un proceso estocástico, cuya naturaleza puede ser caracterizada mediante un modelo. Para efectuar la estimación de un modelo ARIMA se requiere de una serie temporal que cuente con un elevado número de observaciones. Básicamente, la metodología Box-Jenkins consiste en encontrar un modelo matemático que represente el comportamiento de una serie temporal de datos, y permita hacer predicciones únicamente introduciendo el período de tiempo correspondiente.

El método de Box-Jenkins proporciona predicciones sin necesidad de la existencia de ningún tipo de condición previa. Además, una vez encontrado el modelo, se pueden efectuar de manera inmediata predicciones y comparaciones entre datos reales y estimados.

Se utiliza un enfoque de diferenciación en los datos originales para convertir la serie en un proceso estacionario. La figura 3.3 presenta las primeras diferencias de la serie temporal no estacionaria. Se observa que los datos se encuentran a través de una media constante.




Fig. 3.3 Serie diferenciada velocidad del viento.

La función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF) son utilizadas para decidir cuales (si existieran) componentes autorregresivos o de medias móviles se incluirían en el modelo ARIMA. En la figura 3.4 se presenta tanto la ACF, como la PACF de la serie temporal estacionaria.

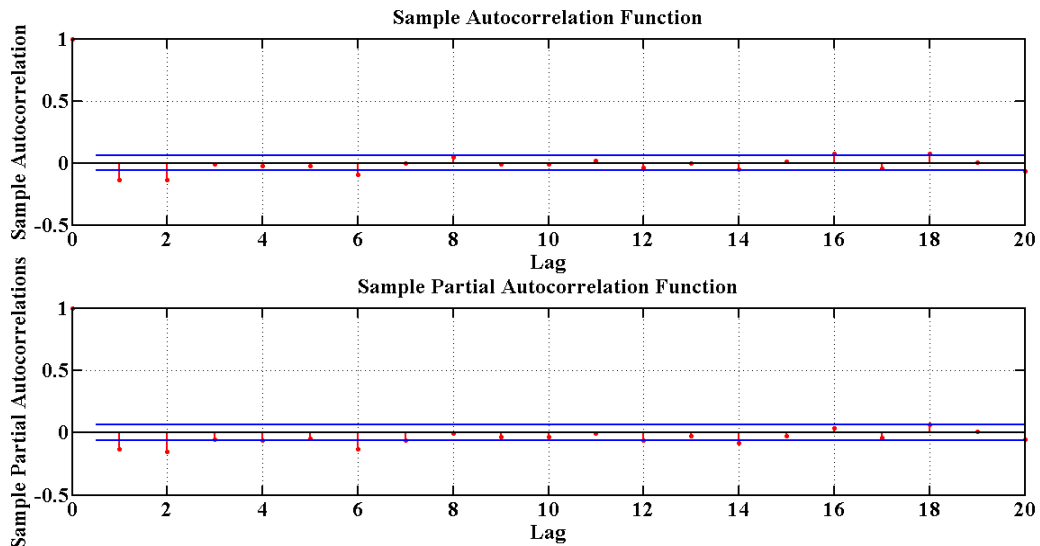


Fig. 3.4 Resultado de la ACF y PACF diferenciada.

Después de un primer cálculo de diferencias, se obtiene un modelo ARMA, ya que tanto la ACF y la PACF de la figura anterior, presentan un fenómeno decreciente y oscilante. Se puede observar que ambas indican un corte en el rezago 1 y 2, lo que indica que el AR (1), AR (2), MA (1) y MA (2) pueden ser adecuados para el modelo.

Finalmente se obtienen los diferentes modelos, eligiéndose el más adecuado, es decir, el que presente los menores índices de error en la predicción.

$$\text{ARIMA (1,1,1); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_1 e_{t-1} + e_t \quad (3.7)$$

$$\text{ARIMA (1,1,2); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_1 e_{t-1} + \phi_2 e_{t-2} + e_t \quad (3.8)$$

$$\text{ARIMA (2,1,1); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_1 e_{t-1} + e_t \quad (3.9)$$

$$\text{ARIMA (2,1,2); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_1 e_{t-1} + \phi_2 e_{t-2} + e_t \quad (3.10)$$

Los parámetros de los modelos se estiman mediante mínimos cuadrados. Conforme se van realizando predicciones, los valores de dichos parámetros son actualizados. Se presentan a continuación, los valores iniciales de los parámetros para cada uno de los modelos.

ARIMA(1,1,1) Model:				ARIMA(1,1,2) Model:			
Conditional Probability Distribution: Gaussian				Conditional Probability Distribution: Gaussian			
Parameter	Value	Standard Error	t Statistic	Parameter	Value	Standard Error	t Statistic
Constant	0.00190911	0.00283221	0.674071	Constant	0.00293342	0.00435419	0.673701
AR{1}	0.764633	0.0580284	13.1769	AR{1}	0.641079	0.0813718	7.8784
MA{1}	-0.881957	0.0460942	-19.3138	MA{1}	-0.682787	0.0848902	-8.04318
Variance	0.26389	0.00827368	31.8952	MA{2}	-0.132314	0.0357143	-3.7048
				Variance	0.260577	0.00861968	30.2305

ARIMA(2,1,1) Model:				ARIMA(2,1,2) Model:			
Conditional Probability Distribution: Gaussian				Conditional Probability Distribution: Gaussian			
Parameter	Value	Standard Error	t Statistic	Parameter	Value	Standard Error	t Statistic
Constant	0.00279086	0.00415596	0.671532	Constant	0.00281089	0.00419864	0.669475
AR{1}	0.78554	0.0541652	14.5027	AR{1}	0.773117	0.236253	3.27241
AR{2}	-0.124973	0.0298305	-4.18944	AR{2}	-0.11514	0.189879	-0.606387
MA{1}	-0.823047	0.0539246	-15.2629	MA{1}	-0.810462	0.237381	-3.41419
Variance	0.260418	0.00877593	29.6741	MA{2}	-0.0113671	0.2175	-0.0522628
				Variance	0.260417	0.00898716	28.9766

### 3.2.1.1 Curva de potencia generador Gamesa G90 - 2.0 MW

La figura 3.5 presente la curva del generador Gamesa G90 - 2.0 MW, que se obtiene a partir de los datos de velocidad del viento y potencia proporcionados por el fabricante del generador. Esta curva es utilizada para realizar una aproximación a la potencia generada, con respecto a los datos de predicción de velocidad del viento del parque eólico Sotavento Galicia, que se presentan en el siguiente capítulo.




Figura 3.5 Curva de potencia generador Gamesa G90-2.0 MW.

### 3.2.2 Caso de estudio Estación meteorológica Chapala

Los datos utilizados en el trabajo son una serie de tiempo de velocidad del viento con un periodo de muestreo de 10 minutos registrados entre octubre y noviembre de 2014, de la Estación Meteorológica Chapala, México. Las coordenadas de la estación son  $103^{\circ}12'06''$  longitud,  $20^{\circ}17'25''$  latitud y 1439 altitud. La figura 3.6 muestra la serie de velocidad del viento (540 muestras). Como puede observarse en dicha figura, la serie temporal es no estacionaria, debido a que no se aprecia que los valores presenten una media constante a través del tiempo.

En la figura 3.7 se observa que la función de autocorrelación (ACF), decrece lentamente, con lo cual se confirma que la serie temporal es no estacionaria. El eje de las abscisas ilustra el número de datos rezagados, para este caso 20, y el eje de las ordenadas muestra la correlación de los datos. La serie temporal se puede transformar en estacionaria obteniendo las primeras diferencias de los valores de la serie temporal no estacionaria.




Fig. 3.6 Serie original velocidad del viento.




Fig. 3.7 Resultados de la ACF y PACF.

Se adopta la metodología de Box-Jenkins, como en el caso anterior, para determinar un modelo ARIMA.

Se utiliza un enfoque de diferenciación en los datos originales para convertir la serie en un proceso estacionario. La figura 3.8 muestra las primeras diferencias de la serie temporal no estacionaria. Se observa que los datos se encuentran a través de una media constante.




Fig. 3.8 Serie diferenciada velocidad del viento.

La función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF) son utilizadas para decidir cuales (si existieran) componentes autorregresivos o de medias móviles se incluirían en el modelo ARIMA. En la figura 3.9 se presenta tanto la ACF, como la PACF de la serie temporal estacionaria.




Fig. 3.9 Resultados de la ACF y PACF diferenciada.

Después de un primer cálculo de diferencias, se obtiene un modelo ARMA, ya que tanto la ACF y la PACF de la figura anterior, presentan un fenómeno decreciente y oscilante. Se puede observar que ambas indican un corte en el rezago 1 y 2, lo que indica que el AR (1), AR (2), MA (1) y MA (2) pueden ser adecuados para el modelo.

Finalmente se obtienen los diferentes modelos, eligiéndose el más adecuado, es decir, el que presente los menores índices de error en la predicción.

$$\text{ARIMA (1,1,1); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_1 e_{t-1} + e_t \quad (3.11)$$

$$\text{ARIMA (1,1,2); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_1 e_{t-1} + \phi_2 e_{t-2} + e_t \quad (3.12)$$

$$\text{ARIMA (2,1,1); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_1 e_{t-1} + e_t \quad (3.13)$$

$$\text{ARIMA (2,1,2); } y_t = \mu_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_1 e_{t-1} + \phi_2 e_{t-2} + e_t \quad (3.14)$$

Los parámetros de los modelos se estiman mediante mínimos cuadrados. Conforme se van realizando predicciones, los valores de dichos parámetros son actualizados. Se presentan a continuación, los valores iniciales de los parámetros para cada uno de los modelos.

ARIMA(1,1,1) Model:

Conditional Probability Distribution: Gaussian

Parameter	Value	Standard Error	t Statistic
Constant	0.0169765	0.0348665	0.4869
AR{1}	0.451635	0.196726	2.29575
MA{1}	-0.662429	0.185288	-3.57514
Variance	2.06938	0.151682	13.6429

ARIMA(1,1,2) Model:

Conditional Probability Distribution: Gaussian

Parameter	Value	Standard Error	t Statistic
Constant	0.0352813	0.0782335	0.450974
AR{1}	-0.142725	0.408496	-0.349391
MA{1}	-0.0433244	0.401822	-0.10782
MA{2}	-0.20828	0.103146	-2.01927
Variance	2.05626	0.14935	13.768

ARIMA(2,1,1) Model:

Conditional Probability Distribution: Gaussian

Parameter	Value	Standard Error	t Statistic
Constant	0.02533	0.0530368	0.477593
AR{1}	0.299912	0.258935	1.15825
AR{2}	-0.100066	0.0879961	-1.13716
MA{1}	-0.488713	0.267699	-1.8256
Variance	2.05907	0.151718	13.5717

ARIMA(2,1,2) Model:

Conditional Probability Distribution: Gaussian

Parameter	Value	Standard Error	t Statistic
Constant	0.0335819	0.0734671	0.457102
AR{1}	-0.277138	0.430108	-0.644347
AR{2}	0.164832	0.293226	0.562132
MA{1}	0.0948737	0.42009	0.225841
MA{2}	-0.390541	0.329431	-1.1855
Variance	2.05032	0.150179	13.6525



### 3.2.2.1 Curva de potencia generador Skystream 3.7 - 2.4 kW

La figura 3.10 ilustra la curva del generador Skystream 3.7 – 2.4 kW, que se obtiene a partir de los datos de velocidad del viento y potencia proporcionados por el fabricante del generador. Esta curva es utilizada para realizar una aproximación a la potencia generada, con respecto a los datos de predicción de velocidad del viento de la estación meteorológica Chapala, México, que se presentan en el siguiente capítulo.




Figura 3.10 Curva de potencia generador Skystream 3.7 – 2.4 kW.

## 4. Resultados y Conclusiones

### 4.1 Resultados Sotavento

La tabla 5 ilustra los resultados de los índices de error de las predicciones para los diferentes modelos ARIMA estimados, de lo cual se observa que el modelo ARIMA (1,1,1) es el que presenta el menor error de uno hasta tres pasos. Los errores son calculados a partir de las ecuaciones (3.3)-(3.6), utilizando los valores reales de velocidad del viento y las predicciones.

Los criterios de evaluación son el error absoluto medio (MAE), el error absoluto medio porcentual (MAPE), el error relativo medio (MSE) y el error cuadrático medio (RMSE) que son utilizados para comparar los resultados de las predicciones de los diferentes pasos por delante y los diferentes modelos.

Tabla 5 Resultados de los índices de error en las predicciones de varios pasos por delante.

Índices	ARIMA (1,1,1)			ARIMA (1,1,2)		
	1-step	2-step	3-step	1-step	2-step	3-step
MAE (m/s)	0.1358	0.4969	0.6576	0.1711	0.5020	0.6783
MAPE (%)	1.6528	5.9966	7.8823	2.1260	6.1003	8.1626
MSE (m/s)	0.0333	0.5911	0.9097	0.0471	0.5891	0.9281
RMSE (m/s)	0.1825	0.7688	0.9538	0.2170	0.7675	0.9634

Índices	ARIMA (2,1,1)			ARIMA (2,1,2)		
	1-step	2-step	3-step	1-step	2-step	3-step
MAE (m/s)	0.1766	0.5052	0.6805	0.1791	0.5085	0.6868
MAPE (%)	2.1927	6.1439	8.1837	2.2164	6.1914	8.2617
MSE (m/s)	0.0506	0.5944	0.9323	0.0525	0.6027	0.9388
RMSE (m/s)	0.2249	0.7710	0.9655	0.2291	0.7764	0.9689

El modelo ARIMA (1,1,1) es el modelo de predicción mejorado, por lo cual, se asume que el modelo ARIMA (2,1,2) representa el 100% del error, y se calcula la parte del porcentaje correspondiente al modelo ARIMA (1,1,1). Un ejemplo se presenta a continuación:

ARIMA (2,1,2)                      0.1791 – – – – – 100%  
 ARIMA (1,1,1)                      0.1358 – – – – – X

$$X = \frac{(0.1358)(100)}{0.1791} = 75.82\%$$

Por lo cual,

$$\%Mejora = 100 - 75.82 = 24.17\%$$

Se realiza este cálculo para todos los índices de error calculados.

El porcentaje mejorado del error MAE para uno hasta tres pasos es 24.17%, 2.28% y 4.25% respectivamente. El porcentaje mejorado del error MAPE para uno hasta tres pasos es 25.42%, 3.14% y 4.59% respectivamente. El error MSE para uno hasta tres pasos es 36.57%, 1.92% y 3.10% respectivamente. El porcentaje mejorado del error RMSE para uno hasta tres pasos es 20.34%, 0.97% y 1.55% respectivamente.

Los resultados que se muestran en las figuras 4.1-4.3 corresponden al modelo ARIMA (1,1,1), de uno hasta tres pasos por delante respectivamente.

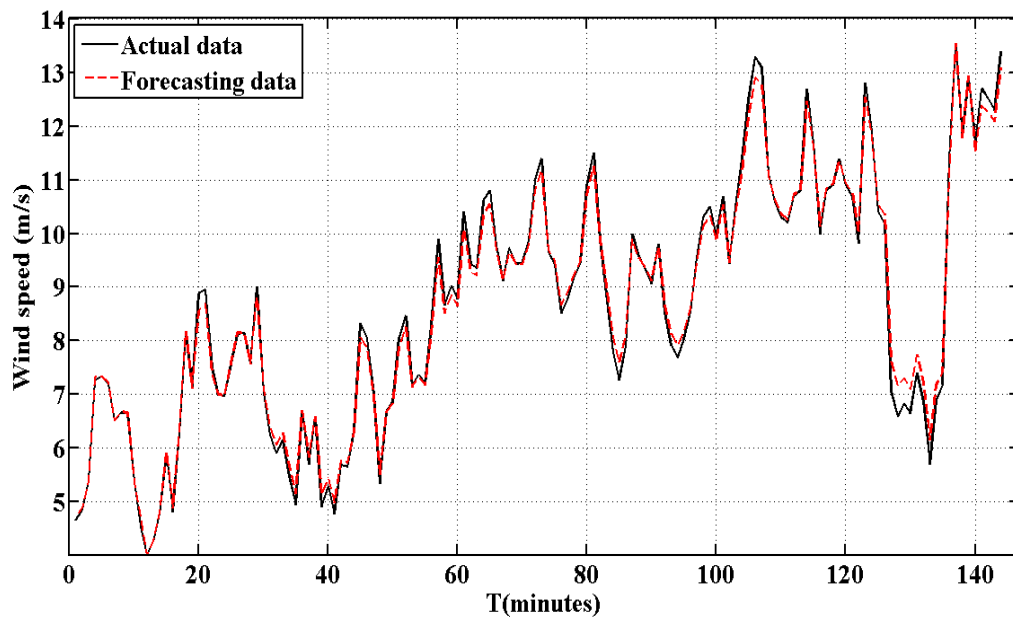


Fig. 4.1 Resultado del pronóstico 1 paso por delante.

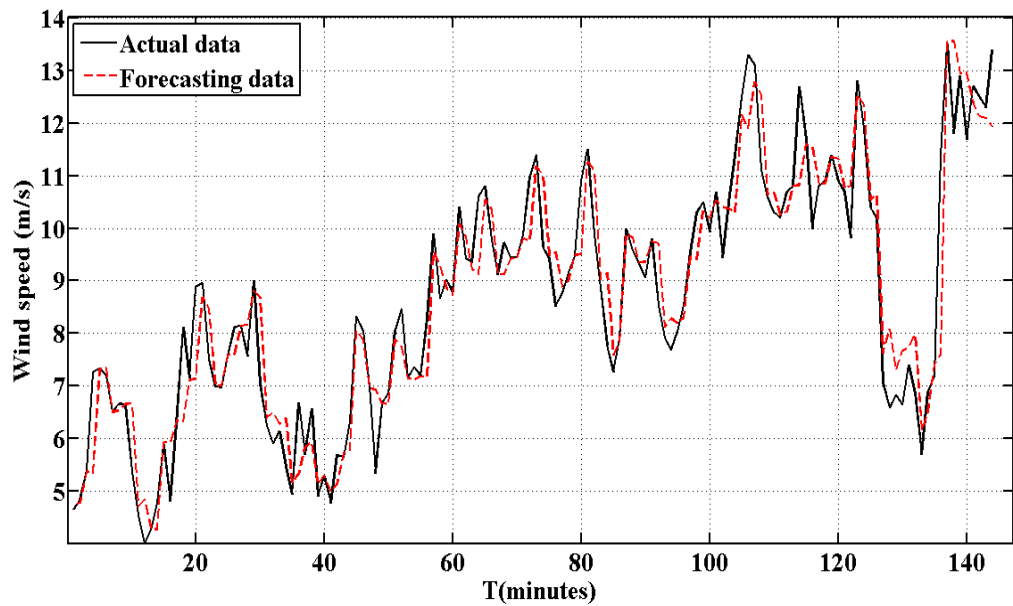


Fig. 4.2 Resultado del pronóstico 2 pasos por delante.




Fig. 4.3 Resultado del pronóstico 3 pasos por delante.

La figura 4.4 presenta la predicción de potencia eólica generada, con el modelo ARIMA (1,1,1) para un paso por delante. La potencia es calculada utilizando los datos de la curva de potencia de la figura 3.5, y las predicciones de velocidad del viento de la figura 4.1. Se realiza una interpolación de datos, esto es, las velocidades descritas en la curva del generador, asignadas a un valor de potencia y las predicciones realizadas por el modelo.

Los resultados no pueden ser comparados con los reales, debido a que dichas mediciones de potencia son inexistentes.

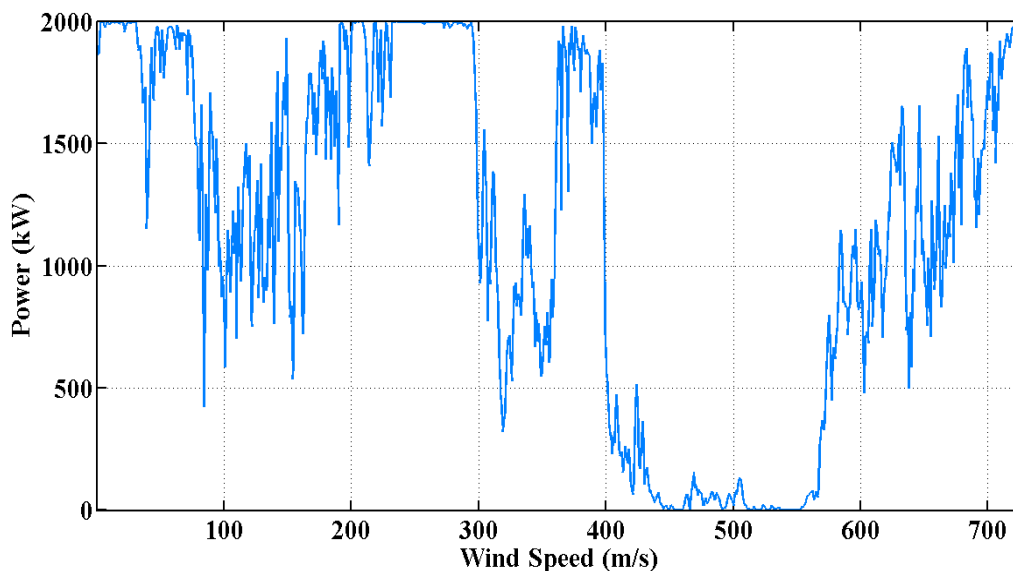


Figura 4.4 Predicción de potencia eólica Sotavento Galicia.

## 4.2 Resultados Estación meteorológica Chapala

La tabla 6 muestra los resultados de los índices de error de las predicciones para los diferentes modelos ARIMA estimados, de lo cual se observa que el modelo ARIMA (1,1,1) es el que presenta el menor error de uno hasta tres pasos. Los errores son calculados a partir de las ecuaciones (3.3)-(3.6), utilizando los valores reales de velocidad del viento y las predicciones.

Los criterios de evaluación son el error absoluto medio (MAE), el error absoluto medio porcentual (MAPE), el error relativo medio (MSE) y el error cuadrático medio (RMSE) que son utilizados para comparar los resultados de las predicciones de los diferentes pasos por delante y los diferentes modelos.

Tabla 6 Resultados de los índices de error en las predicciones de varios pasos por delante.

Indexes	ARIMA (1,1,1)			ARIMA (1,1,2)		
	1-step	2-step	3-step	1-step	2-step	3-step
MAE (m/s)	0.2509	1.0630	1.5721	0.2891	1.1159	1.5924
MAPE (%)	2.1809	7.9867	12.5921	2.2661	8.2738	12.7406
MSE (m/s)	0.1022	2.7727	5.2202	0.1281	2.8689	5.3226
RMSE (m/s)	0.3196	1.6651	2.2848	0.3579	1.6938	2.3071

Indexes	ARIMA (2,1,1)			ARIMA (2,1,2)		
	1-step	2-step	3-step	1-step	2-step	3-step
MAE (m/s)	0.2781	1.1071	1.5814	0.2977	1.1585	1.6357
MAPE (%)	2.1600	8.1654	12.6098	2.4226	8.6906	13.1550
MSE (m/s)	0.1212	2.8630	5.2511	0.1401	3.0454	5.5830
RMSE (m/s)	0.3482	1.6920	2.2915	0.3743	1.7451	2.3628

Se realiza el mismo cálculo que en el caso anterior para obtener los porcentajes de mejora del modelo ARIMA (1,1,1) con respecto al ARIMA (2,1,1). Los resultados se presentan a continuación.

El porcentaje mejorado del error MAE para uno hasta tres pasos es 24.17%, 2.28% y 4.25% respectivamente. El porcentaje mejorado del error MAPE para uno hasta tres pasos es 25.42%, 3.14% y 4.59% respectivamente. El error MSE para uno hasta tres pasos es 36.57%, 1.92% y 3.10% respectivamente. El porcentaje mejorado del error RMSE para uno hasta tres pasos es 14.61%, 4.58% y 3.30% respectivamente.

Los resultados que se muestran en las figuras 4.5-4.7 corresponden al modelo ARIMA (1,1,1), de uno hasta tres pasos por delante respectivamente.




Fig. 4.5 Resultado del pronóstico 1 paso por delante.




Fig. 4.6 Resultado del pronóstico 2 pasos por delante.

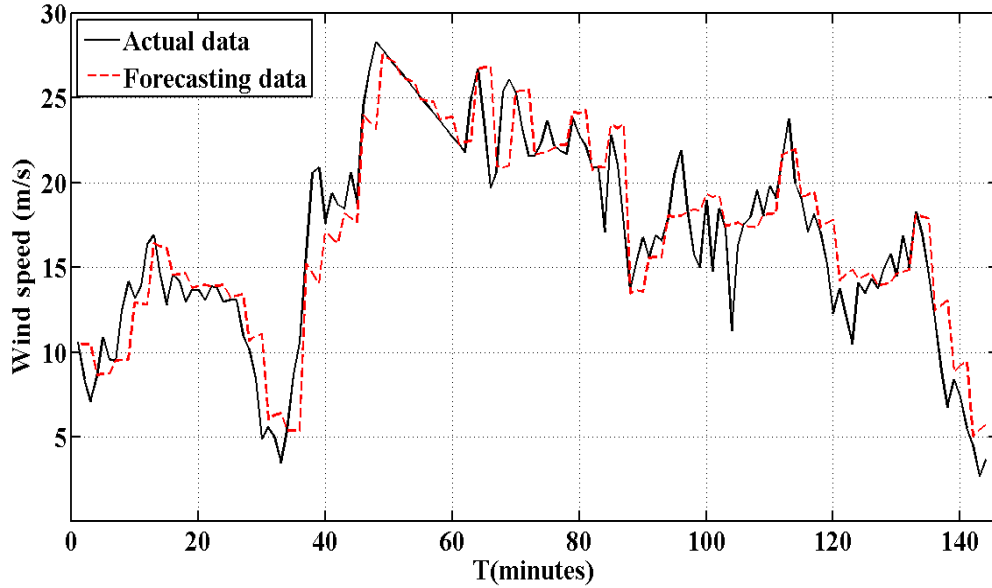


Fig. 4.7 Resultado del pronóstico 3 pasos por delante.

La figura 4.8 presenta la predicción de potencia eólica generada, con el modelo ARIMA (1,1,1) para un paso por delante. La potencia es calculada utilizando los datos de la curva de potencia de la figura 3.10, y las predicciones de velocidad del viento de la figura 4.5. Se realiza una interpolación de datos, esto es, las velocidades descritas en la curva del generador, asignadas a un valor de potencia y las predicciones realizadas por el modelo.

Los resultados no pueden ser comparados con los reales, debido a que dichas mediciones de potencia son inexistentes.




Figura 4.8 Predicción de potencia eólica Chapala.

### 4.3 Conclusiones

En este trabajo se presenta una revisión de los métodos de predicción de velocidad del viento y potencia eólica. Se muestra una tabla con la diversidad de métodos, clasificándolos de acuerdo al horizonte de predicción, las ventajas y desventajas que ofrecen y principalmente la aplicación que estos tienen para el productor de energía eléctrica.

El modelo ARIMA se adopta como método de predicción de velocidad del viento, siguiendo la metodología de Box y Jenkins. Se realiza la comparación de los diferentes modelos estimados y se observa que el modelo ARIMA (1,1,1) es el que presenta los menores índices de error. Se utilizan las métricas de MAE, MAPE, MSE y RMSE para la evaluación del modelo, obteniendo 0.25 m/s, 2.18%, 0.10 m/s y 0.31 m/s respectivamente. De acuerdo con los trabajos realizados por diversos autores, los índices de error que presenta el modelo, se encuentran dentro de los valores aceptables, por lo cual se dice que la predicción de velocidad del viento es buena para un horizonte de predicción de muy corto plazo.

Se destaca en el trabajo el uso de mediciones de velocidad del viento para el caso de México, de la estación meteorológica Chapala con coordenadas de ubicación 103°12'06' longitud, 20°17'25' latitud y 1439 altitud.

Se realiza la estimación indirecta de potencia eólica, mediante la relación potencia generada y velocidad de viento que proporciona el generador Skystream 3.7 en su hoja de datos. Diversos autores deducen que la conversión indirecta es demasiado ideal y no refleja la variabilidad del viento, por lo que como trabajo futuro se propone obtener las mediciones reales de potencia del generador eólico para observar el comportamiento real en la producción de energía eólica.



## Referencias Bibliográficas

- (Abdelaziz,2013) Abdelaziz, A. Y., Rahman, M. A., El-Khayat, M. M., & Abdel, M. (2013). Short Term Wind Power Forecasting Using Autoregressive Integrated Moving Average Approach. *Journal of Energy and Power Engineering*, 2089-2095.
- (Box,1976) J.E.P. Box, G.M. Jenkins, *Times Series Analysis: Forecasting and Control*, Holden-Day, San Francisco, 1976.
- (Costa,2008) Costa A, Crespo A, Navarro J, Lizcano G, Madsen H, Feitosa E. A review on the young history of the wind power short-term prediction. *Renew Sustain Energy Rev* 2008; 12: 1725–44.
- (Dongmei,2011) Dongmei Z, Yuchen Z, Xu Z. Research on wind power forecasting in wind farms. In: *Proceedings of the 2011 IEEE power engineering and automation conference (PEAM)*; 2011. p. 175–8.
- (European,2009) European Wind Energy Association. *Wind Energy - The Facts*. Earthscan Ltd, 2009.
- (Focken,2001) Focken U, Lange M, Waldl H-P. Previento – a wind power prediction system with an innovative upscaling algorithm. In: *Proceedings of the 2001 European wind energy conference & exhibition*; 2001.
- (Foley,2012) Foley AM, Leahy PG, Marvuglia A, McKeogh EJ. Current methods and advances in forecasting of wind power generation. *Renewable Energy* 2012; 37:1–8.
- (Gomes,2012) Gomes, P., & Castro, R. (2012). Wind Speed and Wind Power Forecasting using Statistical Models: AutoRegressive Moving Average (ARMA) and Artificial Neural Networks (ANN). *International Journal of Sustainable Energy Development*, 1(1/2).
- (Jiménez,2007) Jiménez, L. A. F. (2007). Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos (Doctoral dissertation, Universidad de La Rioja).
- (Jiménez,2011) Pronóstico de la velocidad del viento utilizando modelos ARIMA y Redes Neuronales Artificiales. Tesis Maestría, Universidad Michoacana de San Nicolás de Hidalgo.

- (Jung,2014) Jung, J., & Broadwater, R. P. (2014). Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777.
- (Kariniotakis,2004) Kariniotakis G, Pinson P, Siebert N, Giebel G, Barthelmie R. The state of the art in short-term prediction of wind power – from an offshore perspective. 2004 Sea Tech Week; 2004.
- (Kariniotakis,2004) Kariniotakis G, Pinson P, Siebert N, Giebel G, Barthelmie R. The state of the art in short-term prediction of wind power – from an offshore perspective. 2004 Sea Tech Week; 2004.
- (Landberg,2001) Landberg L. Short-term prediction of local wind conditions. *Journal of Wind Engineering and Industrial Aerodynamics* 2001; 89:235–45.
- (Lei,2009) Lei M, Shiyun L, Chuanwen J, Hongling L, Yan Z. A review on the forecasting of wind speed and generated power. *Renew Sustain Energy Rev* 2009; 13:915–20.
- (Liu,2012) Liu, H., Tian, H. Q., & Li, Y. F. (2012). Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*, 98, 415-424.
- (Marti,2003) Marti I, Cabezon D, Villanueva J, Sanisidro MJ, Loureiro Y, Cantero E, et al. LocalPred and RegioPred. Advanced tools for wind energy prediction in complex terrain. In: *Proceedings of the 2003 European wind energy conference & exhibition*; 2003.
- (McGowin,2003) McGowin C. California wind energy forecasting system development and testing. Phase 1: Initial testing. Palo Alto, California: Electric Power Research Institute (EPRI); 2003.
- (Montgomery,2011) Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2011). *Introduction to time series analysis and forecasting* (Vol. 526). John Wiley & Sons.
- (Mörhlen,2004) C. Mörhlen, *Uncertainty in wind energy forecasting*, tesis doctoral, Universidad de Cork, Irlanda, 2004.
- (Sangita,2011) P. Sangita B. and S.R Deshmukh. (2011) Use of support vector machine for wind speed prediction. *Power and Energy Systems (ICPS)*, International Conference, pp.1-8, 22-24 Dec. 2011

- (Shi,2011) Shi, J., Qu, X., & Zeng, S. (2011). Short-term wind power generation forecasting: direct versus indirect ARIMA-based approaches. *International Journal of Green Energy*, 8(1), 100-112.
- (Soman,2010) Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010, September). A review of wind power and wind speed forecasting methods with different time horizons. In *North American Power Symposium (NAPS), 2010* (pp. 1-8). IEEE.
- (Tascikaraoglu,2014) Tascikaraoglu, A., & Uzunoglu, M. (2014). A review of combined approaches for prediction of short-term wind speed and power. *Renewable and Sustainable Energy Reviews*, 34, 243-254.
- (Usaloa,2004) J. Usaola, O. Ravelo, G. González, F. Soto, M.C. Dávila, B. Díaz-Guerra, Benefits for wind energy in electricity markets from using short term wind power prediction tools, *Wind Engineering*, Vol. 28, no. 1, 119-128,2004.



### Noise control

Aerodynamic blade tip and mechanical component design mini- mize noise emissions. In addition, Gamesa has developed the Gamesa NRS noise control system, which permits programming the noise emissions according to criteria such as date, time or wind direction. This achieves the goals of local regulation compliance as well as maximum production.

### Grid connection

Gamesa’s doubly-fed wind turbines and Active Crowbar and over sized converter technologies ensure the compliance with the most demanding grid connection requirements.

Low voltage ride-through capability and dynamic regulation of active and reactive power.




- |   |  |   |  |
|---|--|---|--|
| <ul style="list-style-type: none"> <li>1. Blade</li> <li>2. Blade bearing</li> <li>3. Hydraulic pitch actuator</li> <li>4. Hub cover</li> <li>5. Hub</li> </ul> | <ul style="list-style-type: none"> <li>6. Active yaw control</li> <li>7. Tower</li> <li>8. Main shaft with two bearing houses</li> <li>9. Shock absorbers</li> </ul> | <ul style="list-style-type: none"> <li>10. Gearbox</li> <li>11. Main disc brake</li> <li>12. Nacelle support frame</li> <li>13. Transmission: High-speed shaft</li> <li>14. Doubly-fed generator</li> </ul> | <ul style="list-style-type: none"> <li>15. Transformer</li> <li>16. Anemometer and wind vane</li> <li>17. Top controller</li> <li>18. Nacelle cover</li> <li>19. Hvdraulic unit</li> </ul> |
|---|--|---|--|

### Power Curve Gamesa G90-2.0 MW (for an air density of 1,225 kg/m<sup>3</sup>)

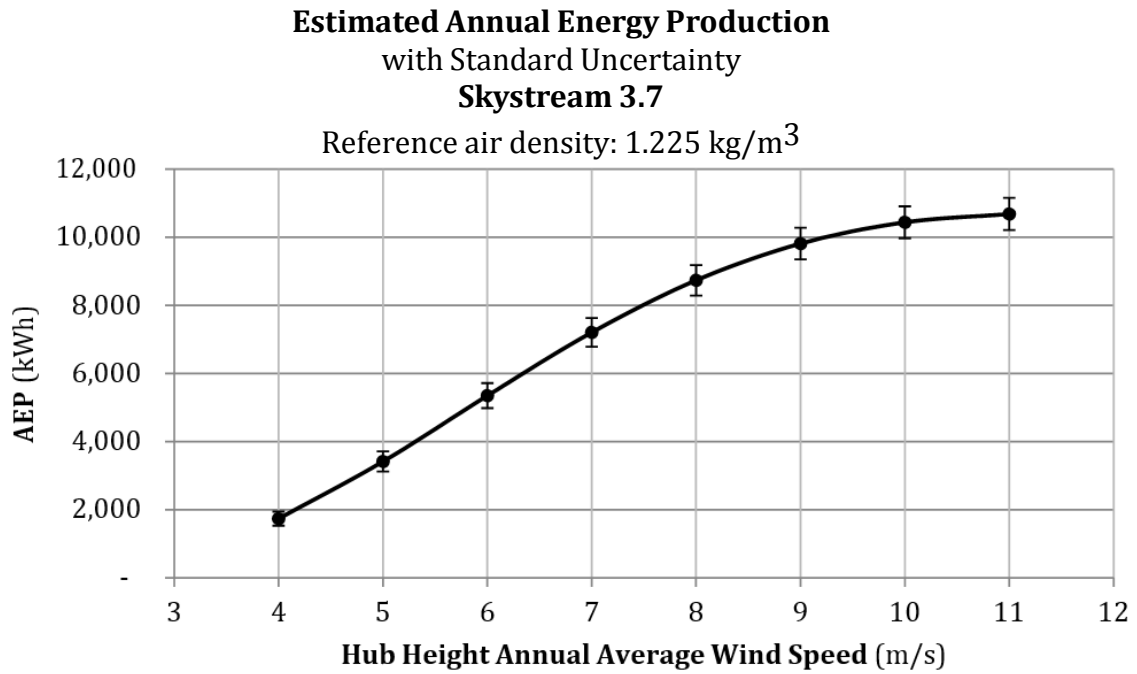
Power curve calculation based on DU (Delft University) and FFAW3 airfoils.

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)	Power (kW)
3	21.3
4	84.9
5	197.3
6	363.8
7	594.9
8	900.8
9	1274.4
10	1633.0
11	1863.0
12	1960.4
13	1990.4
14	1997.9
15	1999.6
16	1999.9
17	2000.0
18-21	2000.0

4. Annual Energy Production Curve



5. Power Curve

