



**UNIVERSIDAD MICHOACANA
DE SAN NICOLÁS DE HIDALGO**



**DIVISIÓN DE ESTUDIOS DE POSGRADO DE LA
FACULTAD DE INGENIERÍA MECÁNICA**

MAESTRÍA EN CIENCIAS EN INGENIERÍA MECÁNICA

**PRONÓSTICO DE LA VELOCIDAD DEL
VIENTO UTILIZANDO MODELOS ARIMA Y
REDES NEURONALES ARTIFICIALES**

TESIS

QUE PARA OBTENER EL GRADO DE MAESTRO EN CIENCIAS

PRESENTA:

ING. MIGUEL JIMÉNEZ MEJÍA

ASESOR:

DR. ERASMO CADENAS CALDERÓN

MORELIA MICHOACÁN, MAYO DEL 2011

Índice

Resumen	I
Abstract	II
Introducción	III
Antecedentes	IV
Justificación	VI
Objetivos	VII
Hipótesis	VIII
Lista de Figuras	IX
Lista de Tablas	XI
Nomenclatura	XII
1. Energía Eólica	1
1.1. Resumen	1
1.2. El viento	1
1.2.1. Circulación planetaria	1
1.2.2. Otros patrones de circulación atmosférica	3
1.2.2.1. La brisa del mar y terrestre	3
1.2.2.2. Los monzones	4
1.2.2.3. El viento en montaña y el de valle	5
1.3. Medición e instrumentación de la velocidad del viento	6
1.3.1. Incertidumbres de las mediciones generadas por los equipos utilizados	6
1.3.2. Características generales de la instrumentación	7
1.3.3. Instrumentos de medición de la velocidad del viento	8
1.3.3.1. Anemómetro de copas	8
1.3.3.2. Anemómetro de propela	10
1.3.3.3. Anemómetro de cometa	10
1.3.4. Medición de la dirección del viento	10
1.3.5. Torres de medición	11
1.3.6. Sistemas de grabación de datos	12
1.4. Influencias del terreno en las características del viento	12
1.4.1. Clasificación del terreno	12
1.4.1.1. Flujo sobre terreno con obstáculos	13
1.4.1.2. Flujo sobre un terreno llano con un cambio en la rugosidad de la superficie	14
1.4.1.3. Características de un terreno no llano: Pequeña escala	14
1.5. Turbinas de viento	15
1.5.1. Turbinas de viento modernas	15
1.5.1.1. Disposición general de las turbinas de viento	15
1.5.1.2. Tamaño	17
1.5.1.3. Rotor	18
1.5.1.4. Sistema de almacenamiento	18
1.6. Fundamentos de energía eólica	20
1.6.1. Energía eólica en el mundo	21

1.6.2. Energía eólica en México	23
2. Metodología Box-Jenkins (ARIMA)	24
2.1. Resumen	24
2.2. Modelos ARIMA	24
2.3. Series de tiempo	25
2.4. Estacionalidad en series de tiempo	25
2.5. Estacionariedad en series de tiempo	25
2.5.1. Métodos para remover la no-estacionariedad en las series de tiempo	26
2.5.2. Diferencia estacional	26
2.5.3. Notación especial	27
2.6. Correlaciones en series de tiempo	27
2.7. Modelos de ruido blanco	28
2.8. Modelos ARIMA para series de tiempo	29
2.8.1. Modelos Autorregresivos	29
2.8.2. Modelos de Medias Móviles	29
2.8.3. Modelos	30
2.8.4. Modelos	30
2.8.5. Modelos estacionales	30
3. Pronóstico de la Velocidad del Viento Utilizando Modelos Autorregresivos Integrados de Medias Móviles	31
3.1. Resumen	31
3.2. Metodología ARIMA	31
3.3. Series de tiempo de velocidades del viento	32
3.4. Generación de modelos	33
3.4.1. Identificación	34
3.4.2. Estimación y prueba	35
3.4.3. Aplicación	36
3.5. Resultados y discusiones	37
4. Redes Neuronales Artificiales	38
4.1. Resumen	38
4.2. Desarrollo histórico	38
4.3. Elementos de una red neuronal artificial	39
4.4. Características de las redes neuronales	39
4.4.1. Redes ADALINE	40
4.4.1.1. Aprendizaje de la red ADALINE	40
4.4.2. Red Backpropagation	41
4.4.3. Aprendizaje de una red Backpropagation	41
4.4.3.1. Inicialización de los pesos	42
4.4.3.2. Presentación de un patrón de entrada	42
4.4.3.3. Cálculo de la salida actual de la red	42

4.4.3.4.	Cálculo de los términos de error para todas las neuronas	43
4.4.3.5.	Actualización de los pesos	43
4.4.3.6.	Repetir el proceso hasta que el término error resulte aceptablemente pequeño.	44
5.	Pronóstico de la Velocidad del Viento Utilizando Redes Neuronales Artificiales	45
5.1.	Resumen	45
5.2.	Análisis de series de tiempo con Redes Neuronales Artificiales	45
5.3.	Preparación de los datos	46
5.4.	Entrenamiento de modelos ADALINE	47
5.5.	Validación ADALINE	49
5.6.	Entrenamiento Backpropagation	50
5.7.	Validación Backpropagation	52
5.8.	Comparación ADALINE con Backpropagation	53
5.9.	Resultados y discusiones RNA	54
6.	Comparación de los Modelos ARIMA y RNA	55
6.1.	Resumen	55
6.2.	Comparación de modelos	55
6.3.	Resultados y discusiones	56
	Conclusiones	60
	Bibliografía	61
	Anexo 1	64
	Anexo 2	66

Resumen

México cuenta con un gran potencial eólico, en el Istmo de Tehuantepec se estima que se podrían instalar más de 6,000 MW eólicos. Otros sitios con gran potencial eólico están localizados en Baja California, Zacatecas, Hidalgo, Veracruz, Sinaloa y Yucatán. Instituciones gubernamentales como Comisión Federal de Electricidad (CFE) y el Instituto de Investigaciones Eléctricas (IIE), estudian estos sitios con gran potencial energético y desarrollan proyectos para la explotación de la energía eólica. Para poder hacer una planeación de la explotación de la energía eólica de manera eficiente en nuestro país, es necesario implementar técnicas para el análisis de series de tiempo como herramientas para el pronóstico de la velocidad del viento.

Hay varias técnicas para hacer pronóstico de series de tiempo, la metodología ARIMA (*Autorregresive Integrated Moving Average*) y las Redes Neuronales Artificiales (RNA) han tenido grandes aplicaciones en el pronóstico de series de tiempo. En este trabajo se pretende comparar estas técnicas para el pronóstico de la velocidad del viento a corto plazo. Algunos autores afirman que la metodología Box-Jenkins (ARIMA) supera a las redes neuronales en el pronóstico a corto plazo. Los datos fueron proporcionados de manera horaria por Comisión Federal de Electricidad (CFE) de la región del Istmo de Tehuantepec, Oaxaca.

Abstract

Mexico has a large wind power potential in the Isthmus of Tehuantepec is estimated that could be installed more than 6,000 MW. Other sites with high wind potential are located in Baja California, Zacatecas, Hidalgo, Veracruz, Sinaloa and Yucatan. Government institutions such as the Federal Electricity Commission (CFE) and the Institute of Electrical Research (IIE) study these sites with great energy potential and develop projects for the exploitation of wind energy. To plan for the exploitation of wind energy efficiently in our country, it is necessary to implement techniques for time series analysis as tools for forecasting wind speed.

There are several techniques for time series forecasting, the ARIMA methodology (Autorregresive Integrated Moving Average) and Neural Networks (ANN) have great applications in time series forecasting. This paper seeks to compare these techniques to forecast wind speed in the short term. Some authors claim that the Box-Jenkins methodology (ARIMA) outperforms neural networks in short-term prognosis. Data were provided on a time by Commission Federal de Electricidad (CFE) in the region of the Isthmus of Tehuantepec, Oaxaca.

Introducción

El petróleo ha sido la forma más conveniente de producción de energía hasta que se empezaron a ver las consecuencias del consumo de este combustible. El ambiente es el más afectado de manera considerable, tanto, que se han visto cambios bruscos del clima y esto preocupa a la sociedad y a investigadores. La dependencia de los combustibles fósiles para la producción de energía ha sido tanta, que la economía de los países depende de ello. Sin embargo, han encontrado otras fuentes de energías que son renovables como son la energía solar, del viento, la biomasa, entre otras. Las energías renovables pueden ser aprovechables y en la actualidad ya se hace de manera eficiente, uno de los principales problemas es la inversión inicial que en muchos casos no se está dispuesto a cubrir, aunque esta inversión puede ser recuperada a mediano o largo plazo.

En México ya se explotan algunas energías renovables como son la radiación solar, la energía cinética del viento, la biomasa, etc. Se cuenta con un gran potencial eólico en lugares como el Istmo de Tehuantepec, las penínsulas de Yucatán y Baja California, así como en Zacatecas por mencionar los más importantes [1]. Instituciones gubernamentales como CFE y el Instituto de Investigaciones Eléctricas (IIE) son las que han hecho posible el aprovechamiento de este recurso energético, ya que son los responsables de los estudios que se han hecho para el aprovechamiento del potencial eólico en los lugares ya mencionados.

La intención de este trabajo de tesis es contribuir al desarrollo tecnológico para la explotación masiva del viento como fuente de energía en México.

Antecedentes

A finales del 2009 se reporta que la capacidad de energía eólica instalada en todo el mundo es de 159,213 MW, de los cuales 38,312 MW fueron agregados en el 2009, la capacidad instalada ha crecido con una tasa del 31.7% desde el 2001. En la figura 0.1 se muestra cómo ha evolucionado la capacidad de energía eólica en todo el mundo desde el 2001 hasta el 2009, se estima que para el 2010 se tendrán más de 200,00 MW instalados [3].



Figura 0.1. Capacidad de energía eólica instalada en todo el mundo

En México se tenían instalados 402 MW a finales del 2009, con 317 MW agregados en ese año, ocupando el primer lugar a nivel mundial respecto a la tasa de crecimiento de potencia instalada y el segundo lugar de Latinoamérica después de Brasil en potencia instalada total a finales del 2009.

Los países que encabezan la lista con mayor potencia eólica instalada son los Estados Unidos de América, China, Alemania, España y la India. En la tabla 0.1 se muestra la potencia instalada en todo el mundo por país en el año 2009, México se encuentra en la posición 27.

Tabla 0.1. Potencia instalada en el mundo [3]

Position 2008	Country	Total Capacity installed end 2009	Add capacity 2009	Growth rate 2009	Position 2008
		[MW]	[MW]	[%]	
1	USA	35,159.0	9,922.0	39.3	1
2	China	26,010.0	13,800.0	113.0	4
3	Germany	25,777.0	1,880.0	7.9	2
4	Spain	19,149.0	2,460.0	14.7	3
5	India	10,925.0	1,338.0	14.0	5
6	Italy	4,850.0	1,114.0	29.8	6
7	France	4,521.0	1,117.0	32.8	7

8	United Kingdom	4,092.0	897.0	28.1	8
9	Portugal	3,535.0	673.0	23.5	10
10	Denmark	3,497.0	334.0	10.6	9
---	---	---	---	---	---
26	Egypt	430.0	40.0	10.3	21
27	Mexico	402.0	317.0	372.9	34
28	Korea (South)	364.4	86.4	31.1	27
---	---	---	---	---	---
80	North Korea	0.2	0.0	0.0	77
81	Algeria	0.1	0.0	0.0	80
82	Bolivia	0.01	0.0	0.0	81
	Total	159,213.3	38,312.0	31.7	120,902.9

En México existen varios lugares en los que se han hecho estudios para el aprovechamiento de la energía eólica, el estado más conocido en el ámbito de la explotación de este recurso es Oaxaca, que ya tiene dos parques eólicos funcionando como son La Venta II en el Istmo de Tehuantepec con 83.3 MW instalados y, Eurus ubicado en Juchitlan de Zaragoza con 250 MW instalados [4], se estima que para el año 2011 se tendrán en operación tres nuevos parques eólicos en la región sur del Istmo de Tehuantepec que generarán 304.2 MW de electricidad. Otras de las regiones de estudio, que se ha certificado que existe un gran potencial por instituciones como Comisión Federal de Electricidad (CFE) y el Instituto de Investigaciones Eléctricas (IIE), son las siguientes: Baja California, Coahuila, Hidalgo, Veracruz, Sinaloa, Yucatán, Quintana Roo y Zacatecas [5].

Para poder hacer una planeación de la explotación de la energía eólica de manera eficiente en nuestro país, es necesario implementar técnicas de pronóstico como herramientas para predecir tanto la velocidad del viento como el potencial eólico de algunas zonas de interés. Algunos de los modelos que más se han utilizado para el pronóstico de la velocidad del viento a corto plazo en los países con interés en la explotación de la energía eólica son: los modelos Autorregresivos Integrados de Medias Móviles (ARIMA) [6, 7], las Redes Neuronales Artificiales (RNA) [2], el método de Reconstrucción de Espacios de Fase (phase space reconstruction) [8], el método de Reconocimiento de Patrones (Pattern Recognition) [9], por mencionar algunos. Estos modelos han probado un funcionamiento de manera eficiente para el pronóstico de la velocidad del viento y la potencia eólica a corto plazo en diferentes países del mundo.

Justificación

México cuenta con un potencial muy importante en cuestión de recursos energéticos renovables, cuyo desarrollo permitirá al país contar con una mayor diversificación de fuentes de energía. Con el parque “Eurus” ubicado en Juchitán de Zaragoza Oaxaca, cuenta con 250.5 MW de potencia instalada, y con la entrada en funcionamiento de tres parques más en el Istmo de Tehuantepec para el 2011, pone a nuestro país como uno de los líderes en Latinoamérica en el rubro de la energía eólica y lo hace figurar de manera importante en el ámbito mundial.

En ese sentido, la intención del trabajo propuesto en este documento, es la de contribuir a la integración de una base tecnológica suficiente para la explotación masiva del viento, como fuente de energía alternativa en México, proponiendo modelos para el pronóstico de la velocidad del viento a corto plazo, que permita realizar el despacho y la planeación de la energía eólica de manera eficiente en las diversas regiones de la República Mexicana con potencial eólico detectado.

Los modelos serán generados a través de diversas técnicas estadísticas y de inteligencia artificial; técnica utilizada en la actualidad para el pronóstico de datos presentados en forma de series de tiempo. Los resultados esperados en el presente proyecto se aplicarán en el sitio seleccionado para el estudio, e incluso, se pretende que la propuesta se extienda a otros campos eólicos de la República Mexicana.

Objetivos

Objetivo principal:

Generar un modelo de predicción utilizando técnicas Estadísticas Autorregresivas y de Redes Neuronales Artificiales (ARIMA y RNA) para pronosticar la velocidad del viento a corto plazo en el Istmo de Tehuantepec Oaxaca, que operen a partir de registros históricos de dicha variable.

Objetivos particulares:

- Contribuir a la integración de una base tecnológica relacionada con el pronóstico de la velocidad del viento para la explotación masiva del mismo, como fuente de energía en México.
- Generar un precedente en el modelado de pronóstico en plantas eólicas, que pueda ser utilizado como referencia en trabajos de modelado en otras regiones del país y otras disciplinas similares.

Hipótesis

Es posible generar un modelo estadístico y de inteligencia artificial que pronostique la velocidad del viento a corto plazo, en base a la información en forma de datos históricos equi-espaciados con los que se cuenta (mediciones de la velocidad del viento en la región sur del Istmo de Tehuantepec), y las técnicas estadísticas avanzadas (modelos ARIMA, modelos no lineales, modelos multivariable, etc.) que se aplican a las series de tiempo.

Lista de Figuras

Figura 1.1. Modelo de Halley (1686)

Figura 1.2. Esquema simplificado de la circulación general de la tierra

Figura 1.3. Brisas marina y terrestre

Figura 1.4. Vientos anabáticos y catabáticos

Figura 1.5. Anemómetro de copas

Figura 1.6. Anemómetro de propela, para la medición de las tres componentes de la velocidad del viento

Figura 1.7. Velea, sensor para medir la dirección del viento

Figura 1.8. Torre de medición de la velocidad, dirección, radiación solar, etc.

Figura 1.9. Aparato de adquisición de datos de viento (Datalogger)

Figura 1.10. Determinación de un terreno llano

Figura 1.11. Estela de la velocidad del viento causada por los obstáculos

Figura 1.12. Efecto de la superficie rugosa en el perfil de rugosidad del viento

Figura 1.13. Disposición típica dentro de la góndola de un aerogenerador de eje horizontal

Figura 1.14. Flujo de aire que llega al rotor

Figura 1.15. Potencia entregada por un aerogenerador

Figura 1.16. Capacidad eólica instalada en todo el mundo

Figura 1.17. Distribución por continente de nueva capacidad de energía eólica

Figura 1.18. Tasa de incremento de energía eólica

Figura 3.1. Metodología ARIMA

Figura 3.2. Series de tiempo por mes

Figura 3.3. Serie de tiempo correspondiente al mes de Enero

Figura 3.4. Serie de tiempo estacionaria

Figura 3.5. FAC y FACP de la serie normal

Figura 3.6. FAC y FACP de la serie transformada

- Figura 3.7.** Correlogramas de residuos de los modelos y respectivamente
- Figura 3.8.** Pronóstico fuera de la muestra
- Figura 5.1.** Proceso de análisis de series de tiempo con Redes Neuronales Artificiales
- Figura 5.2.** Serie de tiempo normalizada
- Figura 5.3.** Modelo 1 (RNA-2C-2VE)
- Figura 5.4.** Modelo 2 (RNA-2C-3VE)
- Figura 5.5.** Pronóstico fuera de la muestra ADALINE
- Figura 5.6.** Modelo 3 (RNA-3C-2-3)
- Figura 5.7.** Modelo 4 (RNA-3C-2-4)
- Figura 5.8.** Modelo 5 (RNA-4C-2-3-2)
- Figura 5.9.** Pronóstico fuera de la muestra Backpropagation
- Figura 6.1.** Mejor modelo para la serie de tiempo de Enero
- Figura 6.2.** Mejor modelo para la serie de tiempo de Abril
- Figura 6.3.** Mejor modelo para la serie de tiempo de Mayo
- Figura 6.4.** Mejor modelo para la serie de tiempo de Junio
- Figura A1.1** Diagrama de flujo ADALINE
- Figura A2.1** Ventana principal
- Figura A2.2** Ventana configuración de red

Lista de Tablas

Tabla 1.1. Principales productores de Turbinas de viento en el mundo

Tabla 3.1. Medidas de error de pronóstico

Tabla 3.2. Modelos ARIMA para el pronóstico fuera de la muestra

Tabla 5.1. Errores de entrenamiento del modelo 1

Tabla 5.2. Error de entrenamiento ADALINE

Tabla 5.3. Medidas estadísticas de error ADALINE

Tabla 5.5. Error de entrenamiento Backpropagation

Tabla 5.6. Medidas estadísticas de error Backpropagation

Tabla 5.7. Medidas estadísticas de error ADALINE y Backpropagation

Tabla 5.8. Resumen de modelos de RNA

Tabla 6.1. Modelos ARIMA y RNA

Tabla 6.2. Valores de los pesos Enero

Tabla 6.3. Valores de los pesos Abril

Tabla 6.4. Valores de los pesos Mayo

Tabla 6.5. Valores de los pesos Junio

Nomenclatura

Energía Cinética

Masa

Velocidad del viento

Potencia entregada por un aerogenerador

Densidad del aire

Área de barrido (Aerogenerador)

Coefficiente de potencia ó aerodinámico de un aerogenerador

Función de Autocorrelación

Función de Autocorrelación Parcial

Número de datos

Valor promedio de las series en el tiempo

Tiempo

Retardo de en el valor

Constante global de la serie de tiempo

Error de pronóstico

Operador de retroceso de las observaciones en series de tiempo

p-ésimo parámetro autorregresivo

q-ésimo parámetro de las medias móviles

Diferencia en la serie de tiempo

Error Cuadrado Medio

Error Medio Absoluto

Patrones de entrada a la RNA

Error de entrenamiento

Valor deseado ADALINE

Valor obtenido por la RNA

Pesos de red ADALINE

Valor de las neuronas

Parámetro de convergencia de entrenamiento de la RNA

Pesos de la capa oculta Backpropagation

Valor de neurona de salida

Función derivable

Valor de neurona oculta

Función derivable oculta

Error de la capa de salida Backpropagation

Valor deseado Backpropagation

Función sigmoïdal para salidas de red binarias

Función lineal derivada para salidas de red lineales

Pesos de salida BackPropagation

Error cuadrado medio de entrenamiento

Valor de la serie de tiempo normalizado

Valor de la serie en el tiempo

Valor mínimo de la serie de tiempo

Valor máximo de la serie de tiempo

Número de entrenamientos (iteraciones)

1

Energía Eólica

1.1. Resumen

En este capítulo se abordan los aspectos generales para la generación y aprovechamiento de la energía eólica, desde el movimiento global de la atmósfera y de los vientos en valles, hasta los equipos especiales necesarios para el aprovechamiento del recurso eólico. Se describen los equipos necesarios para medir la velocidad y la dirección del viento.

1.2. El viento

Los vientos son producto de la atmósfera (capa gaseosa que, por efecto de la fuerza de gravedad, envuelve la superficie de la tierra) que actúa como una gran máquina térmica, en la cual la diferencia permanente de temperatura existente entre los polos y el ecuador proporciona la energía necesaria para la circulación atmosférica. La presión del aire en un punto determinado, es el peso por unidad de superficie de la columna de aire seco que se encuentra por encima y está relacionada con la densidad mediante la ecuación de los gases perfectos. La generación de corrientes de vientos, se debe a la transformación de la energía calorífica en energía cinética, los movimientos del aire pueden ser verticales u horizontales [10].

1.2.1. Circulación planetaria

La mayor parte de los procesos físicos que tienen lugar en la atmósfera son los resultados de intentos de autorregulación que ésta realiza para tratar de reducir las grandes diferencias que resultan de la distribución irregular de la energía, la humedad y la presión en el planeta.

El aire que rodea la tierra se calienta más en contacto con el ecuador que en otros puntos, ya que es la zona donde la radiación solar cae de forma más perpendicular. Así, el grosor de la tropósfera es más grande que en los polos. Si la tierra no tuviera movimiento de rotación y su superficie fuera lisa, el aire que se encuentra sobre el ecuador se elevaría y sería sustituido por el aire más frío de los polos, que son los que reciben la menor cantidad de energía solar. De esta forma se originaría una brisa polar, proveniente de los polos hacia el ecuador, sobre la superficie. En las capas altas de la atmósfera, el aire que se ha elevado en el ecuador se dirigiría hacia los polos, y descendería sobre ellos, ya enfriado para completar el ciclo. Tendríamos así unas circulaciones meridianas a escala hemisférica, con fuentes ascendientes en el ecuador y descendientes sobre los polos. Este es el modelo de Halley, que se ilustra en la Figura 1.1. La consecuencia sería una acumulación de aire frío en los

polos, donde la presión atmosférica sería muy alta, y una continua descendencia del aire en las regiones ecuatoriales, en las cuales la presión bajaría muchísimo.

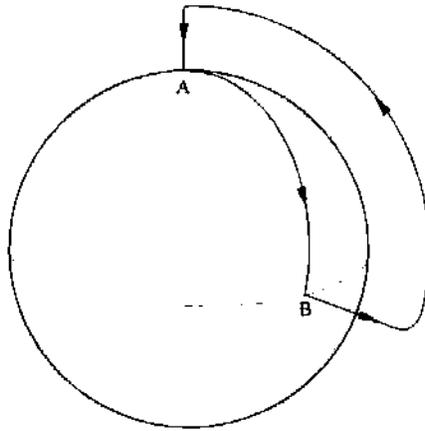


Figura 1.1. Modelo de Halley (1686)

Pero a causa del movimiento de rotación de la tierra, la circulación general se complica bastante más. El aire que se dirige hacia el polo norte por las capas altas, va siendo desviado por el efecto de Coriolis hacia la derecha de su trayectoria inicial, progresivamente con más curvatura, hasta convertirse en vientos del sudoeste. Al llegar a los 30° de latitud (aproximadamente la de las islas Canarias) ha pasado a ser un viento del oeste y se ha enfriado suficientemente como para comenzar a caer hacia el suelo. Una vez en la superficie, se dirige hacia el ecuador, pero no como viento del norte, ya que la desviación de Coriolis vuelve a actuar sobre él y lo convierte en viento del nordeste, donde asciende, y así queda cerrada una célula de convección limitada entre los 30° y el ecuador, denominada *célula de Hadley* (Descrita por Hadley en el año 1735). De todas formas, la desviación del aire en latitudes bajas, cerca del ecuador, no se pueden justificar totalmente por el efecto de Coriolis, debido al bajo valor que esta fuerza toma en esta zona.

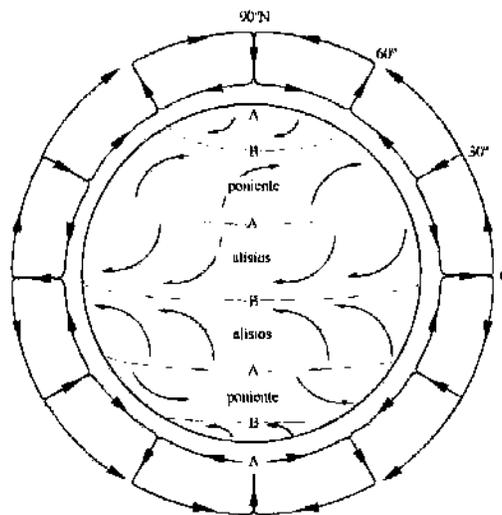


Figura 1.2. Esquema simplificado de la circulación general de la tierra

La Figura 1.2 muestra una circulación muy simplificada, pero es útil para identificar algunas de las características principales de las configuraciones de la presión y el viento. Hay un anticiclón en cada polo, una zona de depresiones o de bajas presiones aproximadamente a los 60° de altitud de cada hemisferio, una franja anticiclónica hacia los 30° de latitud, de la cual parten los vientos *alisios* y los de *poniente* por otro, y un cinturón ecuatorial bastante ancho, la *zona de convergencia intertropical* (ITCZ), en donde los alisios de ambos hemisferios que convergen están tan intensamente caldeados que se elevan sin penetrar en el interior formando intensas corrientes verticales ascendentes. Por esta razón, en el interior de esta zona prácticamente no hay viento en superficie y por eso se le denomina *zona de las calmas ecuatoriales*. La presión en ella es muy baja. Como el aire en esta zona suele ser muy húmedo, su ascendencia continua produce precipitaciones [10].

Es más realista la Figura 1.2 que la Figura 1.1. Muestra como las zonas de altas y bajas presiones en superficie no son continuas si no que hay ciertas regiones geográficamente favorecidas, fundamentalmente a causa de la distribución irregular de océanos y continentes y sus diferentes comportamientos térmicos.

1.2.2. Otros patrones de circulación atmosférica

A causa de ciertas peculiaridades de la topografía de una región o de la interacción entre el océano y los continentes, es bastante corriente el establecimiento de circulaciones de aire de escala local o mayor.

Muchas circulaciones locales, por ejemplo, son determinadas por interacciones entre la atmósfera y la superficie situada debajo de ella. La temperatura de los niveles bajos de la atmósfera depende de que, la superficie de debajo sea agua o tierra y de las características de esta tierra. Así, la temperatura es inferior sobre una zona de arena ligera y húmeda que sobre un terreno oscuro y seco, ya que la arena refleja la radiación solar de forma más efectiva que la tierra oscura. Además, parte de esta energía se hace servir para hacer evaporar el agua y, por tanto, queda menos cantidad de calor para aumentar la temperatura. Por otro lado, en una zona costera, es diferente la temperatura del aire sobre el mar que sobre tierra.

1.2.2.1. La brisa del mar y terrestre

Cuando se aplica calor a un objeto, su temperatura sube, mientras que al enfriarse de nuevo desprende una cantidad equivalente de calor. Pero no todos los materiales tienen la misma capacidad calorífica. Se define el calor específico de una sustancia como la cantidad de calor que se le ha de proporcionar a una unidad de masa para elevar su temperatura 1°C. Por ejemplo, el calor específico del agua es 1 cal/g °C, mientras que el de los minerales que integran las rocas es aproximadamente de 0.2 cal/g °C, es decir, unas cinco veces menor. En consecuencia, una cantidad dada de calor elevará la temperatura de una unidad de masa de las rocas unas cinco veces más que si esta unidad fuese de agua. Esto explica que en un día

cálido y en la costa sea frecuente la aparición de una brisa de mar a tierra, denominada *brisa marina*.

Dado que la radiación solar eleva más la temperatura de la tierra que la del mar, el aire que se encuentra sobre la tierra se calienta y, al perder densidad, tiende a elevarse, con lo que disminuye localmente la presión y, en consecuencia, se produce un gradiente de presión desde el agua hacia la tierra. El aire frío que se encuentra sobre el mar se mueve hacia tierra para ocupar el lugar que ha dejado el aire caliente y refresca las costas con brisas marinas. El aire caliente ascendente se mueve hacia el mar en altura, descendiendo sobre el mar y forma una célula de convección.

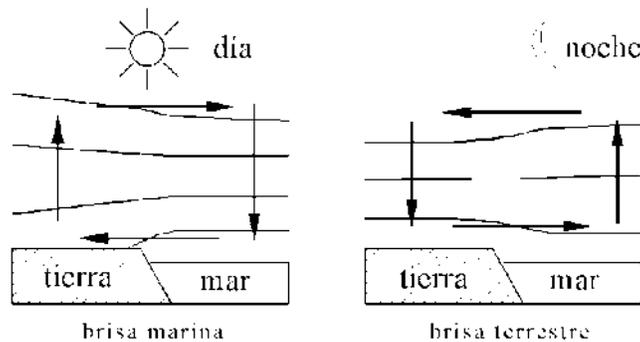


Figura 1.3. Brisas marina y terrestre

Durante la noche el efecto es el contrario: el mar está más caliente que el continente y la circulación del aire se invierte y da lugar a una *brisa terrestre* o *terral* en la superficie.

Estas dos brisas no son de la misma magnitud; mientras que la velocidad del viento en la brisa marina puede llegar a tomar valores de 4 a 7 m/s, la brisa terrestre no suele presentar velocidades superiores a los 2 m/s. La brisa marina es suficientemente intensa como para dominar sobre la circulación a gran escala de la región. De hecho, en las latitudes medias, la fuerza de Coriolis desvía la brisa marina que se mueve hacia tierra, de manera que, en realidad, sopla casi paralela a la línea de costa. Un ejemplo es el viento de *garbí* (del sudoeste) en las costas catalanas, que sopla casi diariamente en las horas centrales del día. Estos vientos locales pueden tener un efecto decisivo sobre la temperatura y la humedad de las zonas costeras; el aire húmedo de la brisa marina forma muy a menudo nubes al ascender sobre la costa.

1.2.2.2. Los monzones

Un mecanismo muy parecido al de las brisas, aunque a mayor escala, es el que produce los vientos monzónicos, de gran importancia climática en ciertas regiones como la India y otras zonas de Asia y África. Mientras que las brisas tienen una escala temporal diaria, los monzones son un fenómeno estacional y tienen mucha más extensión.

Durante el verano, el aire que se encuentra sobre los continentes fuertemente calentados por el sol, asciende y es sustituido por el aire frío procedente del mar, que invade la zona aportando una gran cantidad de humedad. Cuando este aire húmedo avanza tierra adentro, también se calienta y acaba ascendiendo, y en este proceso se condensa parte de su vapor de agua y se libera el calor latente de condensación. Esta liberación de calor intensifica la circulación monzónica, ya que aporta una energía suplementaria que favorece la dilatación y el ascenso del aire. Se producen grandes formaciones nubosas y las lluvias son importantes. Es lo que se conoce con el nombre de *monzón de verano*, que da lugar a la estación húmeda.

En invierno es el aire frío continental el que se desplaza sobre los océanos más cálidos. La circulación se invierte y disminuye drásticamente la cobertura nubosa sobre el continente, lo que da lugar a la estación seca.

1.2.2.3. El viento en montaña y el de valle

En una zona montañosa, durante el día el sol calienta más las laderas de montaña que el valle, de manera que se produce un flujo de aire que asciende desde el valle hasta las cumbres. Se trata del viento *anabático* (ascendente), que alcanza la velocidad más alta a primeras horas de la tarde. Simultáneamente se produce el movimiento del aire siguiendo el eje del valle, en el sentido en que el terreno asciende. Este viento local de valle, generalmente muy flojo, es compensado por un viento de retorno en altura que es alimentado por los vientos anabáticos, que muchas veces queda enmascarado por la circulación general de la zona.

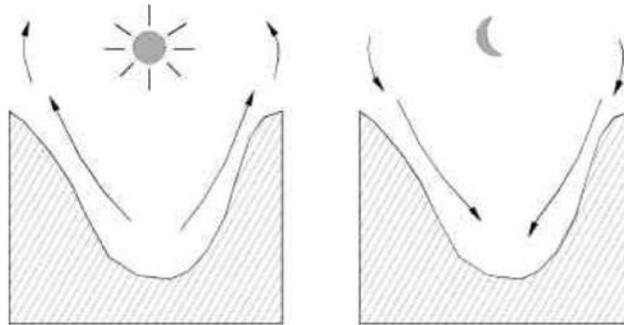


Figura 1.4. Vientos anabáticos y catabáticos

Durante la noche, la circulación se invierte. Las laderas de la montaña se enfrían por radiación y el aire que tienen encima, más frío y denso, desciende desde la cima y se hunde en el valle, lo que da lugar a lo que se conoce con el nombre de *viento catabático* (descendente). Paralelamente se forman vientos de montaña a lo largo del eje del valle, que soplan hacia las zonas más bajas, mientras que en altura aparece también una corriente de retorno que los compensa [10].

1.3. Medición e instrumentación de la velocidad del viento

El uso de datos meteorológicos requiere información sobre parámetros del sitio (localización, altura, periodo de recolección de datos, etc.), de sensores (características y calibración) y el tiempo de datos obtenidos. Existen tres tipos de sistemas de instrumentación usados para la medición del viento:

- Instrumentos usados por servicio meteorológico nacional, destinados al análisis y predicción del clima.
- Instrumentos diseñados especialmente para diseñar y caracterizar el recurso eólico.
- Instrumentos especialmente diseñados, por razones de muestreo, para determinar la intensidad de las ráfagas, turbulencia o información referente al flujo del viento para analizar la respuesta de la turbina de viento.

Para cada aplicación el tipo y cantidad de instrumentos requeridos varía de manera considerable. Para aplicaciones de energía del viento se utilizan generalmente los siguientes equipos:

- *Anemómetros*, para medir la velocidad del viento.
- *Veletas*, para medir la dirección del viento.
- *Termómetros*, para medir la temperatura ambiente del aire.
- *Barómetros*, para medir la presión del aire.

Los instrumentos anteriores, se comprenden principalmente de sensores, acondicionadores de señal y grabadoras.

1.3.1. Incertidumbres de las mediciones generadas por los equipos utilizados

Es evidente que no es posible evaluar la confianza que se puede otorgar a las mediciones de la velocidad del viento, generadas por los equipos de medición utilizados, aún cuando la calibración de éstos se realiza en un periodo de tiempo prolongado (1 año). Sin embargo, los equipos se han utilizado en más de cien países en el mundo, por más de veinte años, en países bajo circunstancias y condiciones parecidas a las planteadas en el presente proyecto, y han hecho posible la instalación de grandes centrales eólicas incorporadas a la red eléctrica.

Aún cuando la instalación de las centrales ha sido exitosa en su mayoría, es necesario generar un procedimiento más apegado al protocolo de medición, con la finalidad de poder calcular las incertidumbres en las mediciones y obtener una precisión más adecuada en la predicción de la potencia de las centrales.

Pese a que es posible tener mejores mediciones, es un hecho que no es objetivo del presente trabajo validar los datos, solamente considerarlos como válidos, desarrollando con ellos, los modelos para pronosticar la velocidad del viento.

1.3.2. Características generales de la instrumentación

Es importante resaltar los siguientes conceptos, previo a la discusión referente a la instrumentación.

Sensor: Un sensor es un dispositivo (ej. Anemómetro de copas, o hilo caliente), el cual reacciona a cambios del medio ambiente. En el caso de un anemómetro de copas, la copa reacciona a la fuerza del viento, mientras que el anemómetro de hilo caliente reacciona al flujo del viento vía un estímulo de temperatura.

Transductor: Es un dispositivo el cual convierte energía de un tipo a otro. En el caso de las mediciones del viento este se refiere al dispositivo que convierte un movimiento mecánico en una señal eléctrica.

Acondicionador de señal: Estos suministran potencia al sensor cuando la requiere, además recibe la señal del sensor y la convierte para que pueda ser grabada o desplegada en pantalla.

Resolución: La resolución está definida como la unidad más pequeña de una variable que es detectable por el sensor, un sensor puede tener una resolución de ± 0.1 m/s ó ± 1 m/s, dependiendo del instrumento.

Exactitud y precisión: La exactitud de un instrumento, se refiere a la diferencia media entre la salida del instrumento y el valor verdadero de la variable medida. Por su parte la precisión hace referencia a la dispersión con respecto a la media.

Error: El error es la diferencia entre lo indicado y el valor verdadero de la señal medida.

Confiabilidad: La confiabilidad de un instrumento, es una medida de la probabilidad de que este continuará su funcionamiento dentro de los límites de error especificados en tiempo y condiciones determinadas.

Reproducibilidad: La proximidad de mediciones de la misma cantidad, en donde las mediciones individuales son hechas bajo diferentes condiciones, por diferentes métodos o diferentes instrumentos, define la reproducibilidad.

Constante de tiempo: El periodo requerido por un sensor para responder al 63.2% de un cambio de un paso en una señal de entrada define este tiempo constante.

Constante de distancia: Es la longitud del flujo que cruza a un sensor para causar que este responda al 63.2% de un cambio de paso de velocidad. Esta se calcula multiplicando el tiempo constante del sensor por la media de la velocidad del viento. Los anemómetros de copas estándar pueden tener distancias constantes tan altas como 10 m, dependiendo de su tamaño y su peso. Los anemómetros de copas pequeños y de bajo peso usados para la

medición de la turbulencia, tienen distancias constantes entre 1.5 y 3 m. Para anemómetros de propela de peso ligero, la distancia constante es de cerca de 1 m.

Tiempo de respuesta: Es el tiempo requerido para que un instrumento registre un porcentaje designado (usualmente el 90% o 95%) de un cambio de paso en la variable que está siendo medida.

Razón de muestreo: Es la frecuencia (Hz) a la cual la señal es muestreada, ésta puede ser una función de un sistema de colección de datos.

Sensibilidad: La sensibilidad es la razón de la escala completa de salida de un instrumento y la escala completa de un valor de entrada.

1.3.3. Instrumentos de medición de la velocidad del viento

Los sensores de los instrumentos de medición del viento pueden ser clasificados de acuerdo a su principio de operación [31] en:

- Transferencia de momento: Copas, propelas y paletas de presión.
- Presión en sensores estacionarios: Tubos de pilot y esferas de arrastre.
- Transferencia de calor: Hilos calientes y películas calientes.
- Efectos Doppler: Acústica y láser.
- Métodos especiales. Desplazamiento de ion, etc.

A pesar del gran número de instrumentos disponibles para la medición de la velocidad del viento, en la mayoría de las aplicaciones destinadas al uso de la energía eólica, generalmente se han utilizado tres sistemas, estos son [12]:

- Anemómetro de copas.
- Anemómetro de propela.
- Anemómetro de cometa.

1.3.3.1. Anemómetro de copas

Los anemómetros de copas utilizan su rotación, la cual varía en proporción de la velocidad del viento, para generar una señal (Figura 1.5). Actualmente los diseños más comunes tienen tres copas montadas en una flecha. La razón de rotación de las copas puede ser medida por contadores numéricos que registran el número de rotaciones, cambio de voltaje (CA o CD) eléctricos o electrónicos o un switch fotoeléctrico.

Los anemómetros de tipo mecánico indican el flujo del viento en distancia. La medida de la velocidad del viento se obtiene dividiendo el flujo del viento por el tiempo. Para sitios remotos, este tipo de anemómetros tienen la ventaja de no requerir fuente de potencia.

Algunos de estos anemómetros también manejaban una pluma para grabar los datos directamente.



Figura 1.5. Anemómetro de copas

Un anemómetro electrónico de copas, proporciona mediciones instantáneas. En la parte baja del mismo está conectado un generador (CA o CD) miniatura y la salida análoga es convertida a velocidad del viento por diversas vías. La respuesta y la exactitud del anemómetro de copas son determinadas por su peso, dimensiones físicas y fricciones internas. Si cambian algunos de estos parámetros la respuesta del instrumento variará. Si se desea medir turbulencia, se deben utilizar sensores pequeños, de poco peso y baja fricción. Típicamente las copas más sensibles tienen una distancia constante de cerca de 1m. Cuando los datos de turbulencia no son requeridos, las copas pueden ser grandes y pesadas con distancias constantes de 2 a 5 m. Los valores típicos de exactitud (basados en pruebas de túneles de viento) de los anemómetros de copas son alrededor de $\pm 2\%$ de la lectura [13].

Los numerosos cambios ambientales pueden causar problemas a los anemómetros de copas y reducir la confiabilidad. Los cambios ambientales más comunes son el escarchamiento y el polvo. El polvo puede alojarse en los cojinetes causando un incremento en la fricción y reducir las lecturas realizadas por el equipo. Si un anemómetro se congela su rotación se alenta o se para totalmente, causando errores en la señal. Lo anterior se puede remediar utilizando un anemómetro de copas calientes, sin embargo, estos requieren una fuente de potencia considerable.

1.3.3.2. Anemómetro de propela

Los anemómetros de propelas utilizan el viento a través de una propela para girar una flecha que está conectada a un generador de CA o CD (el más común), o a una luz para producir una señal de pulso.

Los diseños utilizados para aplicaciones de energía de viento, tienen una respuesta rápida y un comportamiento lineal ante los cambios de velocidad. En una configuración horizontal típica, la propela es girada por una veleta puesta en su parte trasera, la cual también puede utilizarse como indicador de la velocidad del viento.



Figura 1.6. Anemómetro de propela, para la medición de las tres componentes de la velocidad del viento

Las propelas generalmente son de poliestireno, su exactitud y mantenimiento son similares a los anemómetros de copas. Un sistema para medir las tres componentes de la velocidad del viento se muestran en la Figura 1.6.

1.3.3.3. Anemómetro de cometa

En épocas anteriores, los cometas eran utilizados para aplicaciones donde se requerían mediciones del viento a alturas superiores a las alturas de las torres meteorológicas convencionales. Uno de los sistemas de cometa más popular fue el TALA (*Tethered Aerodynamic Lifting Anemometer*). Este utilizaba la comparación a la tensión sobre la línea del cometa como un indicador de la velocidad del viento. Una de las principales desventajas de los dispositivos de este tipo es la pequeña cantidad de datos producidos en comparación con la intensa labor que realizan.

1.3.4. Medición de la dirección del viento

La dirección del viento es medida normalmente con una veleta. Una veleta de viento convencional consiste en una ancha cola que el viento golpea sobre el lado corriente debajo

de un eje vertical girándolo, y un contrapeso corriente arriba para proveer balance en la unión con la veleta y la flecha. La fricción en la flecha es reducida con cojinetes. Las veletas de viento producen señales por el contacto o potenciómetros, Figura 1.7.

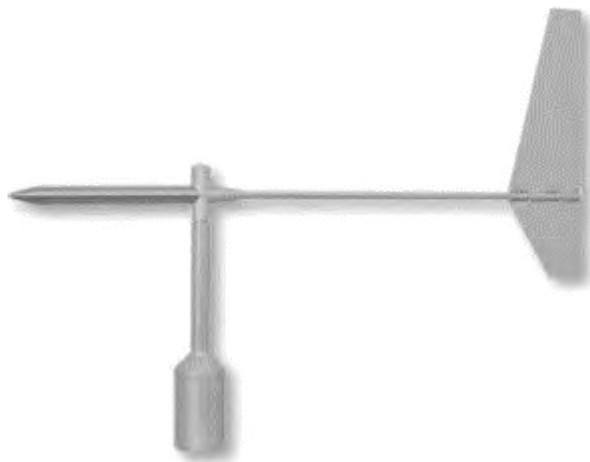


Figura 1.7. Veleta, sensor para medir la dirección del viento

1.3.5. Torres de medición

Una vez que se desea recolectar datos de viento a la altura del cubo de la turbina de viento, se necesitan torres anemométricas que puedan alcanzar desde un mínimo de 10 m, hasta 150 m. Existen varios tipos de torres: con soporte propio y torres tubulares. En la mayoría de los casos las torres deben ser instaladas específicamente para sistemas de medición de viento y en el sitio preciso de interés, Figura 1.8.



Figura 1.8. Torre de medición de la velocidad, dirección, radiación solar, etc.

1.3.6. Sistemas de grabación de datos

Se utilizan diversos sistemas de grabación para desplegar, grabar y analizar los datos obtenidos de los sensores y transductores. Las grabadoras utilizadas en los sistemas de instrumentación de viento se dividen generalmente en:

- Contadores.
- Tiras gráficas.
- Cintas magnéticas.
- Dispositivos de estado sólido.

La grabadora más simple es un sencillo contador o grabador, que graban los valores que pasan a través del sensor. Las alternativas de métodos y sistemas de grabación de datos son diversas y cada uno de estos tiene sus ventajas y desventajas, por lo tanto, su elección es función de las características del proyecto en particular [14], Figura 1.9.



Figura 1.9. Aparato de adquisición de datos de viento (Datalogger)

1.4. Influencias del terreno en las características del viento

Numerosos científicos dedicados al estudio del recurso eólico, enfatizan que la influencia de las características del terreno en la producción de energía de una turbina de viento, puede ser tan grande que la economía del proyecto completo dependerá de la propia elección del sitio [12].

1.4.1. Clasificación del terreno

La definición básica del terreno lo divide en *llano* y *no llano*. Algunos autores definen el terreno *no llano* como un terreno complejo (este es definido como un área en donde los efectos del terreno son evidentes en el flujo que se presenta sobre la tierra considerada). Un terreno *llano* es aquel que tiene pequeñas irregularidades, como un bosque o un pastizal. Un terreno *no llano* tiene elevaciones o depresiones de gran escala, como montañas, cerros, valles y cañones. Para cuantificar que tan llano es el terreno, se debe considerar lo siguiente:

- Las diferencias de elevación entre el lugar en donde se pretende instalar la turbina y el terreno circundante no debe ser más de 60 metros en cualquier lugar dentro de un diámetro de 11.5 km, alrededor de esta.
- Ninguna elevación debe tener una proporción de aspecto (alto - ancho) tan grande como 1/50 dentro de 4 km flujo arriba y flujo abajo del sitio.
- Las diferencias de elevación entre la parte más baja del rotor y la más baja elevación del terreno, debe ser tres veces la máxima diferencia de elevación (h) dentro de 4 km flujo arriba, Figura 1.10.

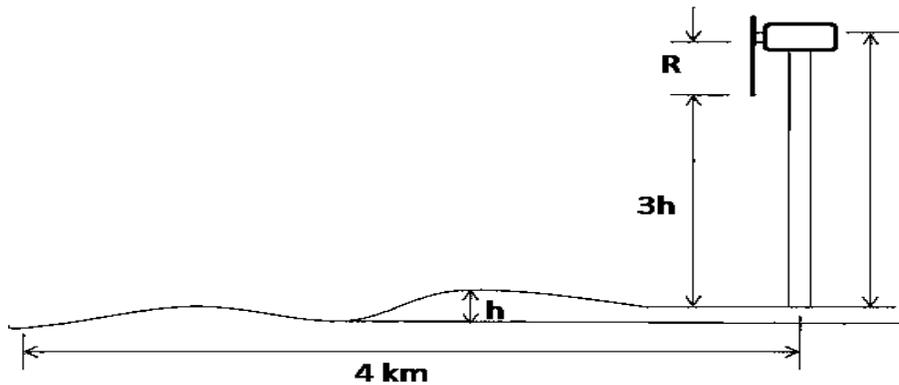


Figura 1.10. Determinación de un terreno llano

Un terreno no llano o complejo de acuerdo con Hister y Pennel, depende de las elevaciones aisladas o depresiones y de los terrenos montañosos. Las condiciones de flujo en terrenos montañosos son complejas, ya que las elevaciones y depresiones ocurren en forma aleatoria, por consiguiente el flujo en dichos terrenos es dividido también en pequeña y gran escala. La diferencia entre las dos, está hecha en comparación con la capa límite planetaria, la cual se asume es de cerca de 1 km.

Para realizar la clasificación anterior, es importante conocer la dirección del viento, si una montaña aislada (ej. 200 m de altura y 1000 m de ancho), estuviera situada a 1 kilómetro al sur del sitio propuesto, el sitio podría ser clasificado como no llano. Sin embargo, si el viento sopla solamente el 5% en esa dirección, con una velocidad media baja de 2 m/s aproximadamente, el terreno puede ser clasificado como llano.

1.4.1.1. Flujo sobre terreno con obstáculos

Para el estudio de los obstáculos creados por el hombre es común proponer un bloque rectangular (Figura 1.11) y considerar el flujo en dos dimensiones, simulando el problema en un programa de cómputo. Este tipo de obstáculos produce una perturbación en las líneas de flujo, formando un remolino antes y después del paso del mismo.

Dicha perturbación debe ser considerada en el momento de instalar una turbina de viento, conociendo el punto donde las líneas de flujo se estabilizan nuevamente, esto ocurre generalmente a una distancia de 15 veces la altura del edificio.

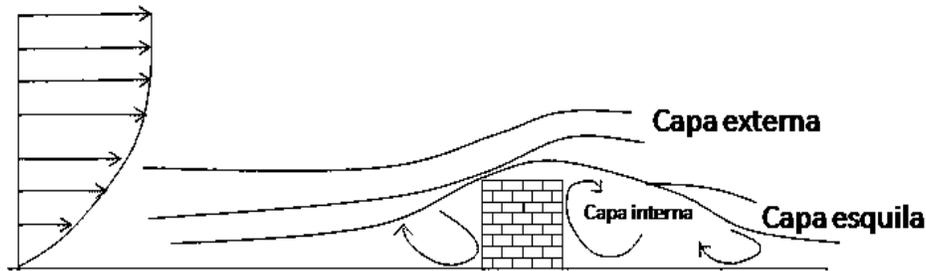


Figura 1.11. Estela de la velocidad del viento causada por los obstáculos

1.4.1.2. Flujo sobre un terreno llano con un cambio en la rugosidad de la superficie

En realidad la superficie de la tierra no es uniforme y cambia significativamente de un lugar a otro, provocando cambios en el perfil de la velocidad del viento [11], Figura 1.12.



Figura 1.12. Efecto de la superficie rugosa en el perfil de rugosidad del viento

1.4.1.3. Características de un terreno no llano: Pequeña escala

La clasificación de un terreno no llano a pequeña escala está dividido en:

- *Elevaciones.* El flujo por encima de terreno elevado tiene características similares al flujo que se presenta alrededor de un obstáculo.
- *Depresiones.* Las depresiones son terrenos más bajos que los circundantes. La aceleración del viento se incrementa si las depresiones la pueden causar, en general, las condiciones de flujo varían según las características de la depresión.

1.5. Turbinas de viento

Los dispositivos utilizados para el adecuado aprovechamiento de la energía del viento han variado de manera considerable en el transcurso del tiempo. El principio fundamental de funcionamiento es la transformación de la energía cinética del viento en energía mecánica, a través de una hélice que transmite un par a un generador eléctrico, por medio de un eje de rotación. Sin embargo, las configuraciones, sobre todo de las hélices, con el tiempo han sufrido transformaciones que han mejorado su rendimiento aerodinámico. De la mano con el desarrollo tecnológico de los equipos, el avance científico ha complementado sistemas con alta eficiencia y calidad. El desarrollo histórico de las turbinas de viento se puede encontrar en [15].

1.5.1. Turbinas de viento modernas

Las turbinas de viento modernas se dividen en dos grupos básicos: las *Turbinas de Viento de Eje Horizontal (HAWT)* y las *Turbinas de Viento de Eje Vertical (VAWT)* o también conocidas como Darrieus.

Actualmente existen más de una veintena de fabricantes en el mundo, con plenas garantías de curva de potencia y de disponibilidad (tanto por ciento del tiempo útil que el aerogenerador está operativo), esta disponibilidad puede llegar al 95% frente al 80% o 90% logrado por las centrales eléctricas convencionales. Los 10 fabricantes de aerogeneradores a nivel mundial por megavatios instalados en 2009 se muestran en la tabla 1.1.

Tabla 1.1. Principales productores de Turbinas de viento en el mundo

Fabricante	País	Potencia (MW)	Fabricante	País	Potencia (MW)
Vestas	Dinamarca	35,000	Suzlon	India	6,000
Enercon	Alemania	19,000	Nordex	Alemania	5,400
Gamesa	España	16,000	Acciona	España	4,300
GE Energy	Alemania/ Estados Unidos	15,000	REpower	Alemania	3,000
Siemens	Dinamarca/ Alemania	8,800	Goldwind	China	2,889

1.5.1.1. Disposición general de las turbinas de viento

Los aerogeneradores actuales de eje horizontal (HAWT) están constituidos por una cimentación de hormigón adecuada al terreno y a las cargas del viento, sobre la cual se levanta una torre, típicamente de acero, de estructura celosía, o bien de tipo tubular de acero u hormigón armado para mejorar su aspecto. La altura a la que son colocados los

aerogeneradores tiene como objetivo evitar las bajas velocidades del viento que se presentan junto a la superficie del terreno. El valor típico de la altura es

, donde , es la altura, el diámetro de barrido de la turbina, y son metros. Al extremo de la torre se fija una góndola giratoria de acero o fibra de vidrio, ver la Figura 1.13, a la cual se accede por el interior de la torre, o por el exterior si se trata de un modelo pequeño. Esta encierra:

- El tren de potencia (eje del rotor (lento), caja multiplicadora (de engranajes planetarios o norma), de régimen de salida hasta unas 1000 a 1500 r.p.m. y elevado rendimiento, típicamente un 90% a 95%, eje rápido y acoplamientos flexibles).
- La máquina eléctrica (generador eléctrico, con un rendimiento del orden del 90%, controles, accionamiento y máquinas auxiliares).
- Mecanismos auxiliares, generalmente hidráulicos (freno de emergencia del rotor, freno de orientación de la góndola, mecanismo de cambio de paso, aerofrenos, sistema de orientación).
- Sistema de control basado en un microprocesador y encargado de la supervisión de las variables operativas, registro de incidencias y control de funcionamiento (arranque, parada, enganche a la red, protección de embalamiento, orientación, paso de las palas). Suele incluir un módulo de comunicación de la base de control central.

En el exterior se encuentra:

- El buje, que une las palas del rotor y que puede incorporar las articulaciones, como cambio de paso, conicidad, etc.
- Las palas, cuyo eje de giro puede estar inclinado algunos grados sobre la horizontal. Son los encargados de convertir la energía cinética del viento a energía mecánica de giro que posteriormente será transformada en energía eléctrica en el generador.
- El mecanismo aerodinámico de orientación, suele ser de veleta o de cola o molino de cola para pequeños tamaños. Para tamaños medios y grandes se usa orientación asistida detectando la dirección del viento por medio de un sensor de dirección y orientando la góndola con un motor eléctrico o hidráulica engranado a una corona horizontal.
- Estación meteorológica, con medida de la velocidad y dirección del viento, temperatura y presión atmosférica.

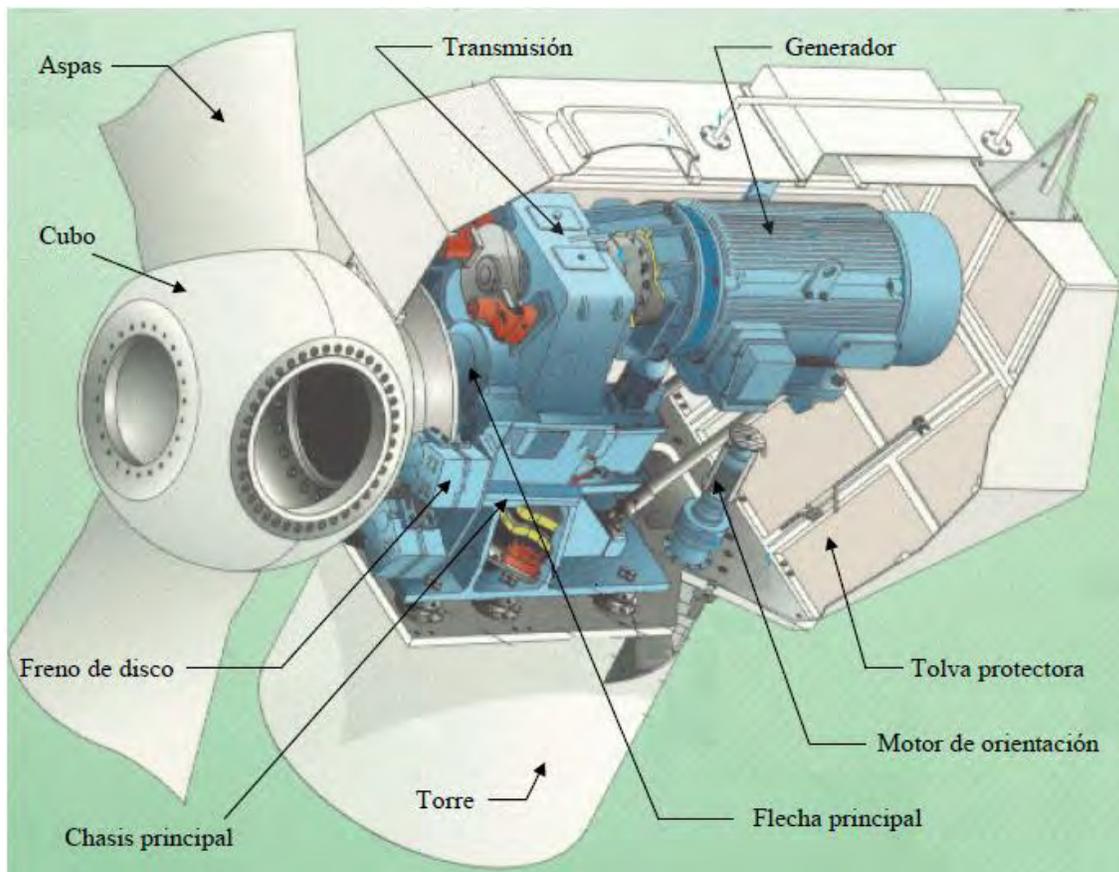


Figura 1.13. Disposición típica dentro de la góndola de un aerogenerador de eje horizontal

1.5.1.2. Tamaño

Los aerogeneradores de pequeña potencia (< 100 kW) y de media potencia (< 700 kW) ofrecen un alto grado de madurez tecnológica, mientras que los cercanos a 700 kW y superiores son de primera generación. Sin embargo, cabe esperar que su puesta a punto sea corta por la experiencia adquirida con los de menor tamaño.

El peso, y por lo tanto el costo, aumenta aproximadamente con el cubo del diámetro del rotor y la potencia con el cuadrado (área barrida) o algo más, pero no tanto como el cubo. Esto debido al pequeño efecto de la mayor velocidad del viento con la altura. Lo anterior parece indicar que el aumento de la escala es negativo. El uso de dos palas en lugar de tres reduce el costo y el peso sobre el buje y el tren de potencia, pero las mayores asimetrías de cargas por el giro del motor que aparecen, crean problemas de fatiga y vibraciones, que intentan aliviarse con el uso de bujes basculantes. Otros recursos para permitir una competitividad a las aeroturbinas de gran tamaño son:

- Empleo de tren de potencia de diseño integrado en lugar de recurrir a un montaje modular.
- Empleo de perfiles aerodinámicos de mayor espesor pero de similares características aerodinámicas específicamente diseñado para aeroturbinas. Esto permite aumentar el modulo a flexión y torsión de la pala y con ello permitir que sea más ligera.
- Empleo de sistemas de control más avanzados que reduzcan las sobrecargas.

Esta situación mantiene un intenso debate técnico sobre si la solución a un aumento de la potencia instalada ha de realizarse sobre la base de los abaratamientos al fabricar en masa unidades de media potencia, o basándose en las hipotéticas ventajas de unidades grandes de nuevo desarrollo.

1.5.1.3. Rotor

La mayoría actualmente son de rotor horizontal, aunque los de tipo Darrieus se siguen fabricando y explorando como candidatos para un futuro. Existe una marcada tendencia a los rotores tripala por su mayor suavidad de giro.

El rotor puede ser una pieza rígida o poseer articulaciones. La más frecuente es la de cambio de paso. Se ha usado la articulación que permite conicidad al rotor, aunque no es muy frecuente. Además, es posible encontrar partes de las aspas que pueden deflectarse, con objeto de actuar de modificadores de la aerodinámica, como pueden ser *flaps* o *frenos aerodinámicos*. Se ha estudiado el dotar de cierta flexibilidad de las aspas con el efecto de que actúe de reductora de vibraciones por amortiguamiento aerodinámico.

En la mayoría de los casos el rotor está situado a barlovento de la torre que es con el objeto de reducir las cargas cíclicas sobre las aspas que aparecen si se situara a sotavento de ella, pues al pasar una pala por la estela de la torre, la velocidad incidente está muy alterada. Debido a este fenómeno, las torres de aeroturbinas con rotores a sotavento son de celosía, por su mayor transparencia al viento.

1.5.1.4. Sistema de almacenamiento

Con el objeto de disponer del beneficio buscado en los periodos de viento flojo o de calma, se dispone de sistemas de almacenamiento de diverso tipo, inútil en sistemas de generación eléctrica conectados a la red.

- Acumulación térmica. La energía extraída del viento se usa para calentar agua, directamente por medio de un freno hidráulico o por calentamiento de resistencias eléctricas tras la conversión a electricidad. El agua se almacena y el aprovechamiento energético posterior sería solo adecuado si se requiere en forma

calórica. Un aerogenerador podría almacenar moviendo un compresor de aire que es enviado a un depósito presurizado, preferiblemente aislado térmicamente, utilizándose posteriormente la energía expansionando el aire a través de una turbina o expansor volumétrico con una eventual combustión previa. Este último sistema proporciona elevados rendimientos, cifrables en un 60% al 80%. Sin embargo, sin combustión, el rendimiento máximo teórico es el 50%, si se deja enfriar el aire comprimido.

- Bombeo de agua. Durante periodos con exceso de producción de energía se puede usar la energía eléctrica para bombear agua hasta un depósito elevado. Durante periodos de viento insuficiente la carga podría alimentarse con una mini-central hidráulica cuyo generador síncrono se conectaría en paralelo con el aerogenerador a través de un sistema de protección y control adecuado. Este método proporciona una eficiencia de energía eléctrica recuperada a energía.
- Baterías. Es el sistema más utilizado actualmente y permite construir sistemas de muy pequeño tamaño, adecuados para balizas, repetidores de señal, estaciones de recogida de datos y puestos de socorro remotos. Su rendimiento es del 60% al 75%. Se emplean baterías especiales que permiten reducciones de su carga hasta el 60% sin daños. Su vida en estas condiciones es del orden de 5 a 7 años. No es adecuado para tamaños grandes por su elevado costo y dificultades de mantenimiento.
- Generación de hidrógeno y celdas de combustible. La electricidad producida descompondría el agua, almacenándose el hidrogeno y eventualmente el oxigeno. Su uso posterior podría ser directo, como combustible, o bien para generar electricidad de corriente continua directamente con una celda de combustible. El rendimiento de recuperación gira en torno al 50%, pudiendo llegar al 70%. Se estima que es el sistema de almacenamiento del futuro para grandes instalaciones.
- Volante de inercia. Se almacena la energía en un volante capaz de girar a elevado régimen en un recinto al vacío, que impida la resistencia aerodinámica, probablemente haciendo uso de cojinetes magnéticos. Este sistema es capaz de absorber potencias instantáneas elevadas, resultando por ello conveniente a las fuentes fluctuaciones de la energía eólica. Logran un rendimiento de recuperación alto, del orden del 80%. Otras de sus ventajas es una vida operativa larga, del orden de 20 años. El intercambio de energía puede ser electromagnético o por medio de un tren de engranajes.
- Desalación del agua. En lugares donde coincida la demanda de agua potable con la disponibilidad de energía eólica y su impacto ecológico sea aceptable, es posible recurrir a emplear la energía sobrante en desalinizar agua, la cual es fácilmente almacenable y proporciona una utilidad completa.

1.6. Fundamentos de energía eólica

En la energía eólica se aprovecha la cantidad de movimiento del aire. La energía cinética de una masa de aire que se desplaza viene determinada por la llamada “ley del cubo”. Dicha ley resulta al considerar un flujo laminar de aire perpendicular a la sección transversal de un cilindro, y desplazándose a una velocidad v como se muestra en la figura 1.14.

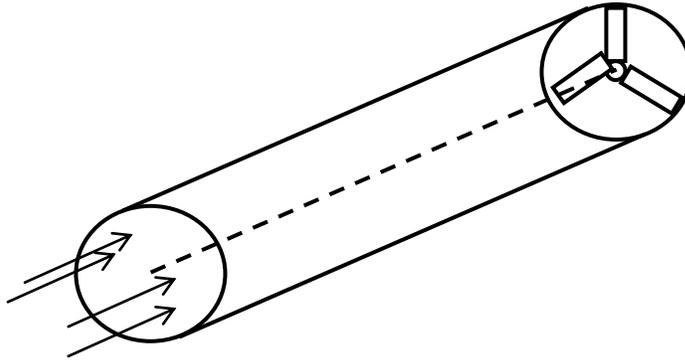


Figura 1.14. Flujo de aire que llega al rotor

La energía cinética, E_c , del flujo está dada por:

$$E_c = \frac{1}{2} m v^2$$

Donde m es la masa de aire en el cilindro. Se puede convertir la expresión de la energía cinética en una expresión de potencia, dividiéndola por el tiempo, teniendo entonces:

$$P = \frac{E_c}{t} = \frac{1}{2} \frac{m}{t} v^2$$

Donde $\frac{m}{t}$ representa la razón del flujo de aire a lo largo del cilindro. La masa de aire en el cilindro es igual a la densidad del aire por el volumen del cilindro, esto es $m = \rho V$. Pero la longitud L del cilindro dividida por el tiempo es igual a la velocidad v , por lo tanto, se tiene que la razón de flujo de aire $\frac{m}{t}$ es igual a $\rho A v$. Sustituyendo $\frac{m}{t}$ por $\rho A v$ en la ecuación anterior, la expresión para la potencia queda de la siguiente manera:

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

Esta es la ecuación para el análisis de la potencia del viento, y puede ser escrita de la siguiente forma:

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

La potencia P está dada generalmente en watts. El valor de la densidad del aire en condiciones estándar (nivel del mar, 0° C) es de $\rho = 1.225 \text{ kg/m}^3$, este valor es el comúnmente usado para los cálculos de la energía eólica.

La potencia entregada por un aerogenerador está afectada por las eficiencias aerodinámicas, mecánica, y eléctrica [16], Figura 1.15.

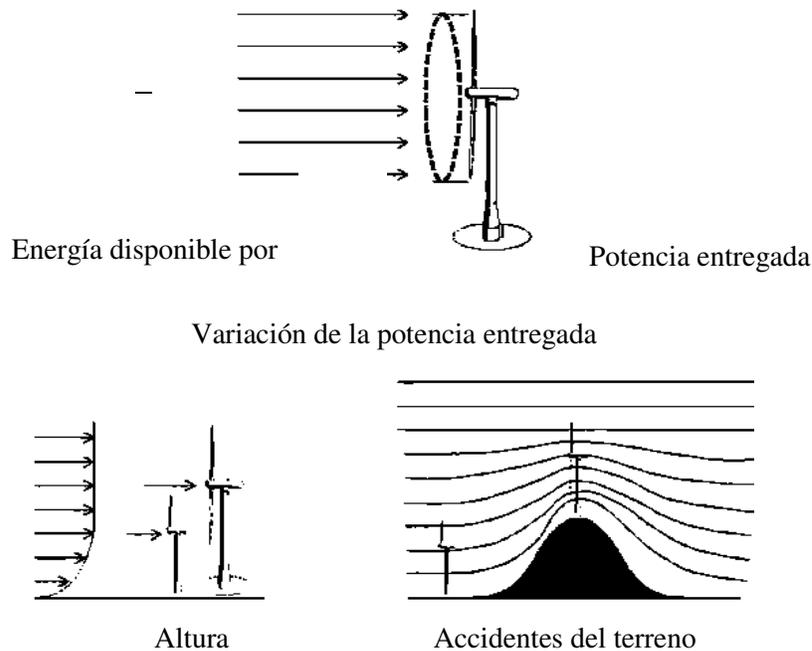


Figura 1.15. Potencia entregada por un aerogenerador

1.6.1. Energía eólica en el mundo

A finales del 2009 la capacidad de energía eólica instalada en todo el mundo fue de aproximadamente 159,213 MW, de los cuales 38,318 MW fueron agregados en el mismo año. La capacidad de energía eólica mostró una tasa de crecimiento del 31.7%, la tasa más alta desde el 2001. La tendencia indica que la capacidad instalada es del doble cada tres años.

Todas las turbinas instaladas en el 2009 en todo el mundo han generado 340 TWh por año, equivalente a la demanda eléctrica total de Italia, la séptima economía más grande del mundo, y equivale al 2% del consumo eléctrico global.

Se estimaba que para el año 2010 se superen los 200,000 MW de energía eólica instalada en todo el mundo, figura 1.16. Basado en un desarrollo acelerado y en la mejora de políticas, la WWEA (World Wind Energy Association) predice que para el 2020 se tendrán 1,900,000 MW de capacidad eólica instalada.



Figura 1.16. Capacidad eólica instalada en todo el mundo

En la figura 1.17 se observa la evolución de la capacidad de energía eólica instalada por año en regiones y continentes. Se puede observar que en el continente europeo el porcentaje de capacidad instalada ha disminuido dramáticamente desde el año 2004, mientras que en Norteamérica y Asia tienen una tendencia de crecimiento. En el resto del mundo no ha habido cambios desde el 2004.

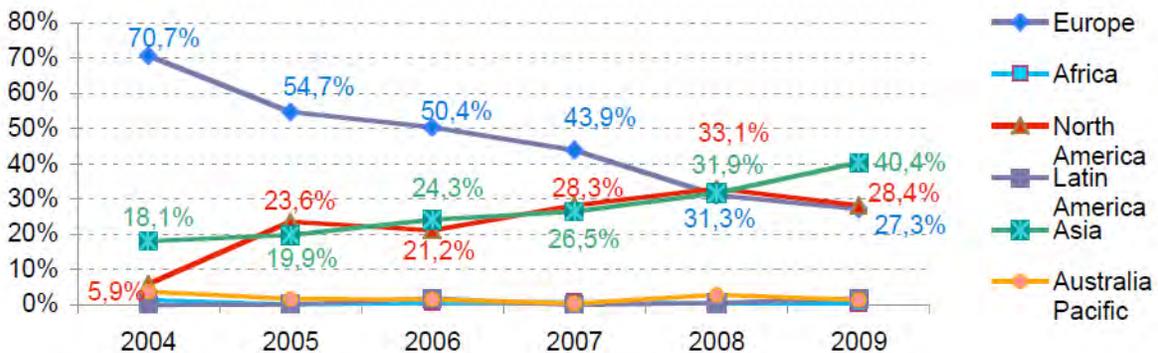


Figura 1.17. Distribución por continente de nueva capacidad de energía eólica

En el continente de África se tienen instalados apenas 770 MW, de los cuales 169 MW fueron instalados en el 2009, lo que representa un incremento del 28%. En Asia se tenían instalados 39,961 MW a finales del 2009, con un incremento del 63.3% con respecto al año anterior, con 15,500 MW agregados en ese año. El continente de Asia es el que más capacidad eólica agregó en el 2009 y le sigue el continente europeo. En el continente europeo se agregaron 10,474 MW, a finales del 2009, sumando un total de 76,218 MW. En Australia y Oceanía se agregaron 555 MW en el año 2009, sumando 2,388 MW. En Norteamérica se tenían instalados 38,478 MW, de los cuales se agregaron 10,872 MW, y solo los Estados Unidos de América agregó 9,922 MW. En Latinoamérica se tuvo un

incremento del 113.3% en el año 2009, de 659 MW que se tenían en el 2008 se incrementaron 747 MW de los cuales 402 MW fueron instalados en México [3].

1.6.2. Energía eólica en México

México cuenta con 402 MW instalados a finales del 2009, de los cuales 317 MW fueron instalados en ese año con una tasa de incremento de 372% (ver figura 1.18), lo que lo coloca en primer lugar con más porcentaje de potencia instalada de todo el mundo seguido por Turquía con 138.9%.

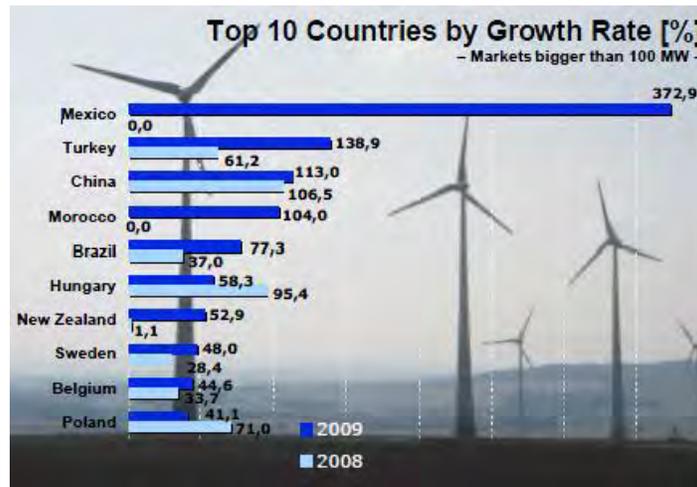


Figura 1.18. Tasa de incremento de energía eólica

Nuestro país ocupa el segundo lugar en potencia instalada en Latinoamérica después de Brasil, que contaba con 600 MW instalados a finales del 2009. Se tiene estimado que para el año 2011 entren en funcionamiento tres nuevos parques eólicos en la región sur del Istmo de Tehuantepec, Oaxaca, que generarán 304.2 MW de electricidad [17]. En el estado de Oaxaca se encuentra el principal recurso eólico de México, se han estimado que en el Istmo de Tehuantepec se podrían instalar más de 6,000 MW eólicos. Otros sitios con gran potencial eólico se encuentran localizados en los estados de Baja California, Zacatecas, Hidalgo, Veracruz, Sinaloa y Yucatán [5].

2

Metodología Box-Jenkins (ARIMA)

2.1. Resumen

Se presenta un breve repaso de los conceptos básicos de series de tiempo, así como los métodos para la preparación de las mismas para generar modelos de pronóstico. Se presenta también, la metodología ARIMA que es una técnica estadística para la generación de modelos de pronóstico.

2.2. Modelos ARIMA

Los modelos Autorregresivos Integrados de Medias Móviles, [*Autorregresive Integrated Moving Average*] (ARIMA), fueron popularizados por George Box y Gwilym Jenkins a principios de 1970. Y sus nombres son frecuentemente usados como sinónimos de los modelos generales ARIMA aplicado al análisis y pronóstico de series de tiempo [18].

Una parte fundamental de esta metodología es que los datos temporales de la variable a estudiar indican las características de su estructura probabilística. Es importante observar que esta técnica permite explicar la variable involucrada utilizando exclusivamente una variable exógena: su propio pasado [19]. La consideración exclusiva de los valores pasados de una determinada variable para explicar su evolución presente y futura supone, al mismo tiempo, una ventaja y un inconveniente [18]:

- La ventaja radica en hecho de no necesitar distintas series de datos (distintas variables) referidas al mismo periodo de tiempo (característica común en todos los modelos univariantes) y, al mismo tiempo, se ahorra la identificación y especificación del modelo.
- El inconveniente es que, al renunciar en la inclusión de un conjunto más amplio de variables explicativas, no se atienden a las relaciones que sin duda existen entre casi todas las variables involucradas en el fenómeno.

En el caso de la energía eólica las mediciones de la velocidad del viento se presentan en forma de series de tiempo, en promedios generalmente compuestos de algunos minutos (10 minutos generalmente) u horarias.

Las técnicas más importantes para hacer inferencias sobre el futuro con bases a lo ocurrido en el pasado son las que analizan las series de tiempo.

En este capítulo se presenta una introducción a las series de tiempo y a la metodología ARIMA que servirá como base para generar modelos de pronóstico para la velocidad del viento a corto plazo en la región sur del Istmo de Tehuantepec en Oaxaca.

2.3. Series de tiempo

Una serie de tiempo se describe como un conjunto de observaciones medidas secuencialmente a través del tiempo. Las series de tiempo pueden ser medidas de manera discreta o continua. Las primeras son medidas en intervalos de tiempos fijos e iguales. Las series de tiempo continuas se obtienen cuando las observaciones son registradas continuamente bajo un intervalo de tiempo [20].

Las series de tiempo tienen un gran impacto en la representación de datos experimentales y en la solución de problemas en muchos campos de la ciencia. Por ejemplo, las series de tiempo son muy comunes en el campo de la economía, en donde representan las cifras de desempleo al mes o en las cotizaciones diarias del mercado de valores. En la medicina, con la medición de la presión arterial que podría ser útil para la evaluación de los medicamentos utilizados en el tratamiento de la hipertensión, etc. Una de las aplicaciones más importantes del análisis de las series de tiempo es en la solución de problemas en física y ciencias ambientales. Investigaciones más modernas pueden centrarse en, si el calentamiento está presente en las mediciones de la temperatura global o si los niveles de contaminación pueden influir en la mortalidad diaria en alguna ciudad [21].

Hay dos características importantes que se pueden identificar en una serie de tiempo y que son importantes para poder hacer un buen análisis, como son la estacionalidad y la estacionariedad.

2.4. Estacionalidad en series de tiempo

La Estacionalidad está definida como un patrón que se repite en intervalos de tiempos iguales. Por ejemplo, las ventas de petróleo son altas en invierno y bajas en verano, indicando un patrón de estacionalidad cada doce meses. Si el patrón es consistente, el coeficiente de autocorrelación tendrá un valor elevado y positivo, indicando la existencia de la estacionalidad de la serie.

En general la estacionalidad se puede encontrar identificando un coeficiente de autocorrelación grande en el retardo que refiere la estacionalidad. Para datos mensuales, con estacionalidad, es común encontrar coeficientes altos en los retardos 12, 24, 36, etc. [22].

2.5. Estacionariedad en series de tiempo

Los datos de una serie son estacionarios cuando no existe tendencia, es decir, crecimiento o decremento en los datos. Los datos tienen que ser aproximadamente horizontales a lo largo de los ejes temporales. En otras palabras, los datos fluctúan sobre una media constante, independientemente del tiempo, y la varianza es aproximadamente constante.

Usualmente se puede evaluar la estacionariedad usando las técnicas gráficas, y observando lo siguiente:

- Si la serie no presenta evidencia de un cambio en la media en el tiempo, entonces decimos que la serie es estacionaria en la media.
- Si la serie presenta un cambio obvio en la varianza con respecto del tiempo, entonces la serie es estacionaria en la varianza.

2.5.1. Métodos para remover la no-estacionariedad en las series de tiempo

La tendencia y otros patrones que indican la no-estacionariedad en el nivel de las series de tiempo resultan en autocorrelaciones positivas que dominan el diagrama de la FAC. Por lo tanto, es importante remover la no-estacionariedad, pues se puede apreciar una estructura diferente a la real que afectará la construcción del modelo. Una alternativa para remover la no-estacionariedad, es el método de la diferenciación. La diferenciación en las series de tiempo se definió como el cambio entre cada observación de la serie original. La expresión 2.1 ejemplifica lo anterior.

La serie diferenciada cuenta con $n-1$ valores, debido a que no es posible calcular una diferencia del primer valor.

Utilizar la primera diferenciación es una herramienta muy usual para remover la no-estacionariedad. Sin embargo, ocasionalmente la diferenciación de los datos es necesario realizarla en una segunda ocasión. La presentación de esta operación se aprecia en la expresión 2.2.

La serie anterior cuenta con $n-2$ valores. En la práctica generalmente no se ocupan más de dos diferenciaciones porque, comúnmente, los datos reales envuelven estructuras con no-estacionariedades de primer o segundo nivel [20].

2.5.2. Diferencia estacional

Con datos estacionales, los cuales son no-estacionarios, puede ser apropiado tomar series estacionales. Una diferencia estacional es la diferencia entre una observación y su correspondiente observación del año anterior. De esta manera si se cuenta con datos mensuales con un patrón cada doce meses, la diferencia estacional sería:

En general una diferencia estacional D_s , es el cambio entre observaciones separadas por periodos de tiempo s , donde t es la referencia de la estación. Para datos anuales D_{12} , para datos que se repiten cada cuatro meses D_4 , etc.

2.5.3. Notación especial

Existe una notación usual en el manejo de las diferencias, lo cual involucra el operador ∇ , de la siguiente manera:

En otras palabras, ∇ opera sobre X_t , y tiene el efecto de retroceder a la observación un periodo. Para datos mensuales, se puede aplicar el siguiente operador:

Y una diferencia estacional seguida de una diferencia de primer orden se escribiría de la siguiente manera:

La notación anterior es conveniente para simplificar los términos de la diferenciación y de esta manera poder controlar el manejo de expresiones complicadas.

2.6. Correlaciones en series de tiempo

La herramienta posiblemente más importante en el análisis de series de tiempo es la Función de Autocorrelación (FAC). Esta puede ser usada de dos maneras diferentes, como una herramienta puramente descriptiva o como una parte de un procedimiento más general para la identificación de un modelo apropiado para una serie de tiempo. La FAC mide la relación estadística entre las observaciones de una serie de tiempo, y está definida como la relación de la covarianza entre la varianza como se muestra en la siguiente expresión.

Al obtener r_1 , se encuentra la relación lineal que existe entre el valor presente X_t y su primer retardo. De la misma manera que ocurre con r_2 , respecto del retardo numero 2, y así sucesivamente. El valor de los coeficientes siempre se encuentra entre -1 y 1 , y no puede sobrepasar dicho valor. A la gráfica de dicha función es llamada correlograma.

Otra herramienta importante para el análisis de series de tiempo con la metodología Box-Jenkins, es la Función de Autocorrelación Parcial (FACP). Esta FACP es usada, en

conjunto con la FAC, para distinguir el orden de parámetros en procesos autorregresivos [18, 23]. La FACP esta definida por la siguiente expresión.

Donde

En donde el primer valor de la FACP es igual que la FAC:

2.7. Modelos de ruido blanco

Un modelo estadístico de ruido blanco es aquel en donde la observación X_t , está compuesta de dos partes (ecuación 2.9), un nivel global μ y un componente de error aleatorio ϵ_t , el cual no está correlacionado periodo a periodo.

El modelo de ruido blanco es fundamental en diversas técnicas de análisis de series de tiempo, de hecho, cualquier modelo adecuado de pronóstico debería estar compuesto de errores de pronóstico con características de ruido blanco [20].

Teóricamente, todos los coeficientes de autocorrelación para las series de números aleatorios deben ser cero. Sin embargo, generalmente se cuenta con muestras finitas, de tal manera que las autocorrelaciones obtenidas no serán exactamente cero. Lo anterior fue demostrado por [24, 25]. De la misma manera que otras características de ruido blanco, como su comportamiento normal, media cero y error estándar σ , dónde n es el número de observaciones en la serie. La información anterior puede ser desarrollada en hipótesis similares a las pruebas estadísticas t y F .

Si la media es cero y el error estándar es σ , para ruido blanco, se esperaría que el t de los coeficientes de la muestra esté entre $\pm \frac{1.96}{\sqrt{n}}$. Si no es el caso, la serie probablemente no es ruido blanco. Por esta razón es común indicar líneas a una distancia de $\pm \frac{1.96}{\sqrt{n}}$, cuando se presenta la función de autocorrelación. Estos límites son conocidos como valores críticos.

2.8. Modelos ARIMA para series de tiempo

Se define un modelo como autorregresivo si la variable endógena de un periodo es explicada por las observaciones de ella misma correspondientes a periodos anteriores, añadiéndose, como en los modelos estructurales, un término de error.

2.8.1. Modelos Autorregresivos

Los modelos Autorregresivos se abrevian con la palabra AR , y se indica el orden del mismo de la siguiente manera: $AR(p)$... etc. El orden del modelo expresa el número de observaciones retrasadas de la serie temporal analizada que intervienen en la ecuación. Un modelo $AR(p)$ tendría la siguiente ecuación:

Un modelo autorregresivo de orden p , tendría la expresión genérica:

Existen restricciones específicas para los valores de los parámetros autorregresivos. Para $AR(p)$. Para $AR(p)$, las siguientes tres condiciones se deben cumplir:

Para $AR(p)$, obviamente se deben cumplir más condiciones, sin embargo, un modelo con más parámetros será difícil de manejar.

2.8.2. Modelos de Medias Móviles

Un modelo de los denominados de medias móviles es aquel que explica el valor de una determinada variable en un periodo t , en función de un término independiente y una sucesión de errores correspondientes a periodos precedentes, ponderados convenientemente. Estos modelos se denotan normalmente con las siglas MA (Moving Average), seguidos, como en el caso de los autorregresivos, del orden entre paréntesis. De esta manera, un modelo con p términos de error $MA(p)$, respondería a la siguiente expresión:

Las mismas restricciones indicadas para los modelos autorregresivos, son requeridas para los modelos MA : para $MA(p)$, se requiere $MA(p)$. Para $MA(p)$, las siguientes tres condiciones son necesarias:

De la misma manera para θ , existen condiciones adicionales.

2.8.3. Modelos

Los elementos básicos para los modelos ϕ y θ , pueden ser combinados para producir una gran variedad de modelos. Por ejemplo, un modelo ϕ y θ , también llamados ϕ - θ , se representa con la siguiente expresión:

Aquí \hat{y}_t , depende del valor previo \hat{y}_{t-1} , y del término de error previo ϵ_{t-1} .

Usando los operadores de la notación especial en la ecuación 2.13, se puede escribir de la siguiente manera:

Finalmente un modelo ϕ - θ de alto orden se define en los siguientes términos:

Las restricciones se aplican individualmente a los modelos, es decir, no varían debido a la mezcla.

2.8.4. Modelos

Si se adiciona un comportamiento debido a una no-estacionariedad a un modelo ϕ - θ , se esta generando un modelo ϕ - θ - I . La ecuación para el caso más simple, es la siguiente:

La parte I , indica una diferenciación y genera la conformación de un modelo ϕ - θ - I en un modelo ϕ - θ - I :

2.8.5. Modelos ϕ - θ - I estacionales

Una adición final se hace a los modelos ϕ - θ - I . Esta se hace involucrando una parte estacional S , donde S , representa el número de periodos por estación y S la parte estacional del modelo [26].

Pronóstico de la Velocidad del Viento Utilizando Modelos Autorregresivos Integrados de Medias Móviles

3.1. Resumen

Se presenta aplicación de la metodología Box-Jenkins para la generación de modelos de pronóstico a corto plazo de velocidades del viento de la región sur del Istmo de Tehuantepec, Oaxaca. Se utilizará la primera serie de tiempo (Enero) para la aplicación de la metodología, y finalmente, se resumen los resultados para todas las series con las que se cuenta.

3.2. Metodología ARIMA

En el capítulo anterior se explicó de manera general la clasificación y las partes en que se conforman los modelos ARIMA. En la Figura 3.1 se presenta de manera resumida en un diagrama de flujo el procedimiento que se utilizará para la generación de modelos.

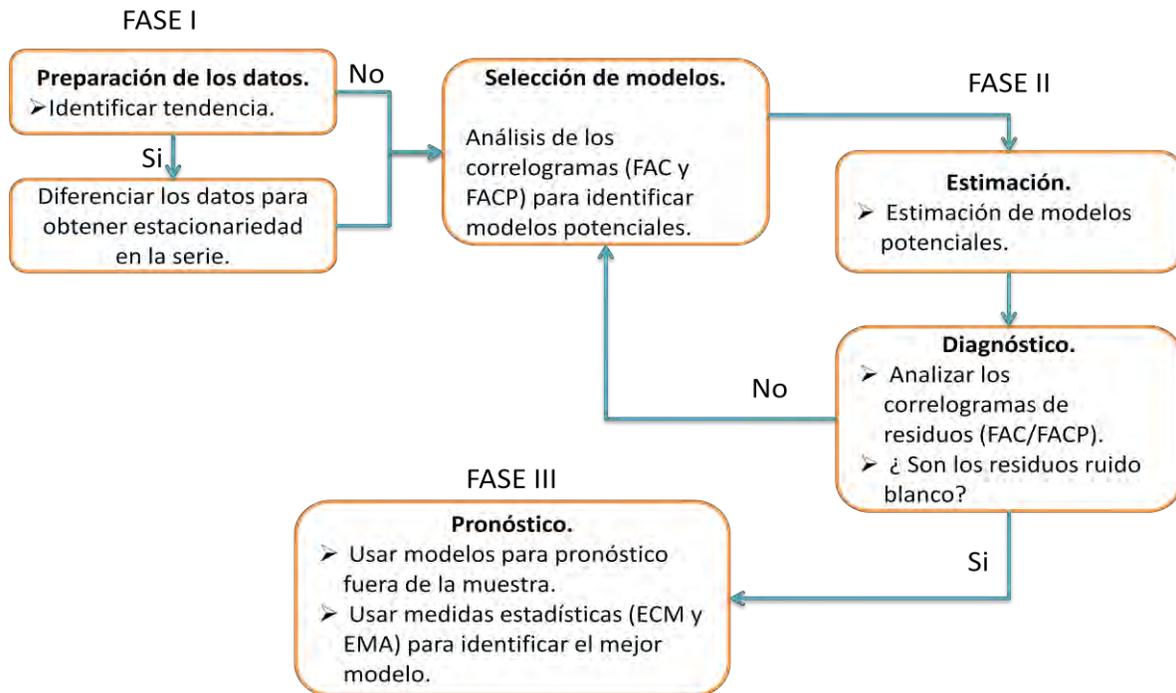


Figura 3.1. Metodología ARIMA.

La Figura 3.1 muestra que la metodología para el pronóstico de la velocidad del viento a corto plazo se basa en tres fases.

- Identificación.
- Estimación y pruebas.
- Aplicación.

La fase de identificación consta de preparar los datos de la serie de tiempo, que consiste en identificar si la serie es estacionaria o no, si es el caso, se aplican procedimientos para eliminar la no-estacionariedad, como diferenciar la serie para estabilizar la varianza y obtener una media constante. Después se hace un análisis de la serie de tiempo con la Función de Autocorrelación (FAC) y la Función de Autocorrelación Parcial (FACP) para identificar modelos potenciales.

En la fase de estimación y pruebas se calculan los parámetros de los modelos propuestos seleccionando el mejor, tomando un criterio adecuado tomando en cuenta los modelos de ruido blanco. El diagnóstico de los modelos se hace analizando los residuos con la FAC y la FACP, si el resultado presenta características de ruido blanco se sigue con la siguiente fase, si no, regresa a la fase de identificación.

La última fase consta de usar los modelos para realizar el pronóstico fuera de la muestra, para seleccionar el mejor modelo se usan medidas estadísticas como el Error Cuadrado Medio (ECM) y el Error Medio Absoluto (EMA) cuyas ecuaciones se presentan a continuación:

—

—

Con las ecuaciones 3.1 y 3.2 se analizan los errores de los modelos y se selecciona el que presente los errores más pequeños.

3.3. Series de tiempo de velocidades del viento

En la región sur del Istmo de Tehuantepec la Comisión Federal de Electricidad (CFE) realizó las mediciones de la velocidad del viento a 10 m sobre el nivel del piso. Los datos fueron obtenidos en forma horaria durante los meses de Enero a Junio de 1999. En la Figura 3.2 se muestran las series de tiempo que se analizarán con la metodología ARIMA.

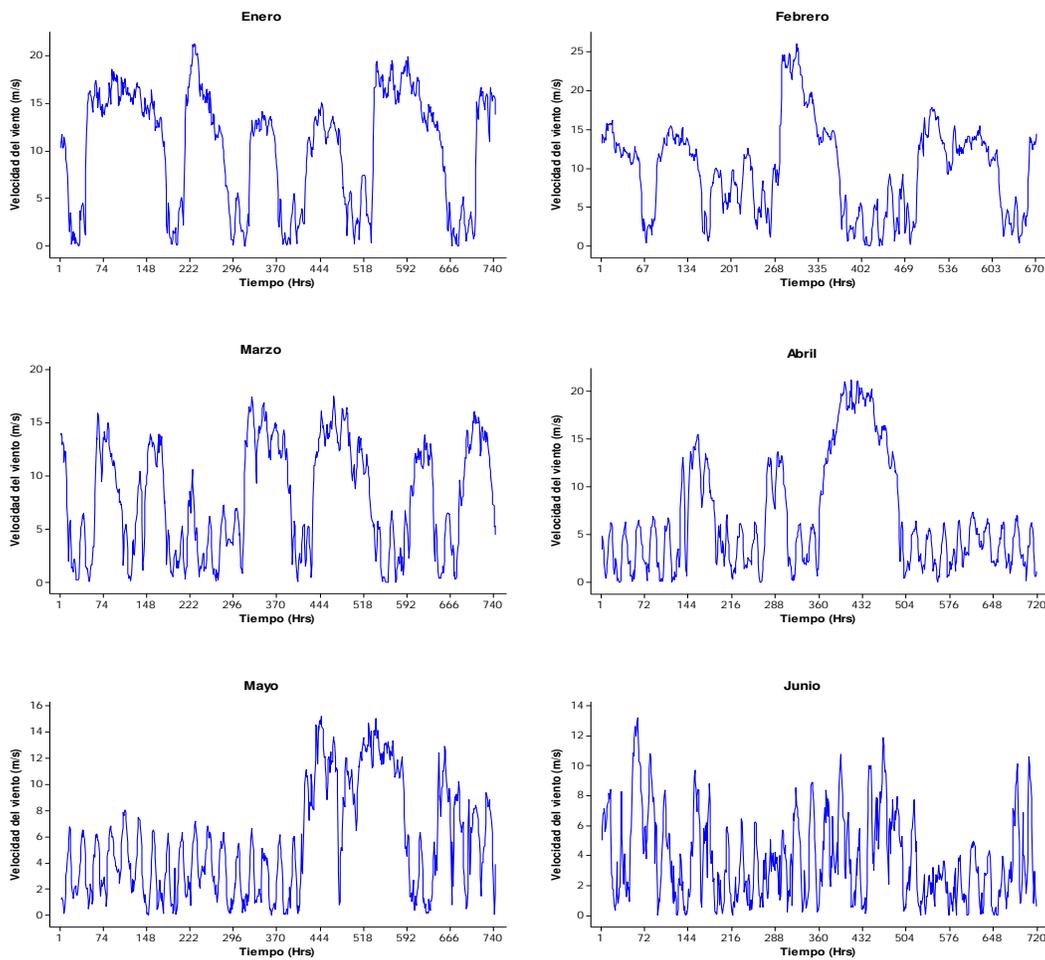


Figura 3.2. Series de tiempo por mes

3.4. Generación de modelos

Se tienen 6 series de tiempo correspondientes a mediciones del mes de Enero a Junio, que se muestran en la Figura 3.2. Para la fase de aplicación de los modelos se dejó un 15% de cada una de las series.

En la Figura 3.3 se muestra la serie de tiempo correspondiente al mes de Enero con la cual se generará el modelo. La serie cuenta con 634 datos y se reservaron 110 datos para el pronóstico fuera de la muestra (fase 3 de la metodología ARIMA).

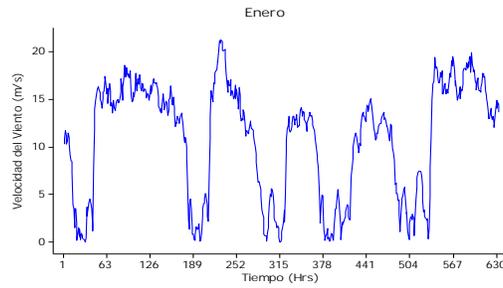


Figura 3.3. Serie de tiempo correspondiente al mes de Enero

3.4.1. Identificación

Una de las dificultades del análisis de velocidades del viento es que no se puede estimar de manera sencilla si la serie presenta estacionariedad, por lo que a veces es conveniente que no se haga la diferenciación de la serie. Sin embargo, en este trabajo se analizan las dos alternativas para observar las diferencias de los modelos resultantes. En la Figura 3.4 se presenta la serie transformada, utilizando la ecuación 2.1.

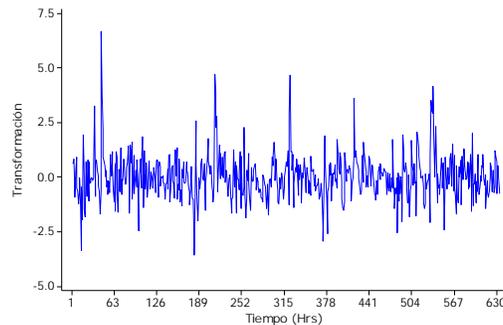


Figura 3.4. Serie de tiempo estacionaria

Para continuar con la primera fase se analizará la serie normal y la transformada con las funciones FAC (ecuación 2.7) y FACP (ecuación 2.8) con ayuda del software Minitab®, obteniendo los resultados que se presentan en la Figura 3.5.

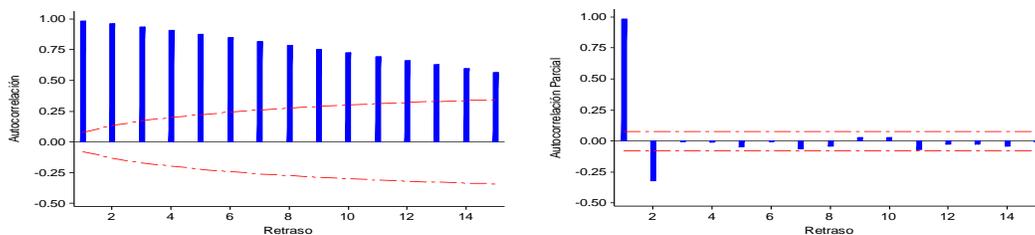


Figura 3.5. FAC y FACP de la serie normal

De la Figura 3.5 se puede deducir que se puede proponer un modelo $AR(2)$, por la forma en que caen los valores de la FAC y, porque son dos los retrasos que sobresalen el límite de significancia en la FACP. Además, se propone este modelo porque el retraso de la FACP llega casi al valor de 1, lo que significa que es muy fuerte la relación del valor presente con el primer retraso y que alcanza a tener relación con el segundo retraso. Los límites de significancia se usan a un 5%. La expresión representativa para este modelo es la ecuación 3.3.

La Figura 3.6 muestra la FAC y la FACP de la serie transformada. Los correlogramas muestran que solo sobresale un valor al límite de significancia, por lo que es posible determinar que la relación del valor presente respecto del primer retraso es de aproximadamente de 0.3, y que por simple inspección de los correlogramas no es posible determinar la relación que se pudiera tener con el segundo retraso.

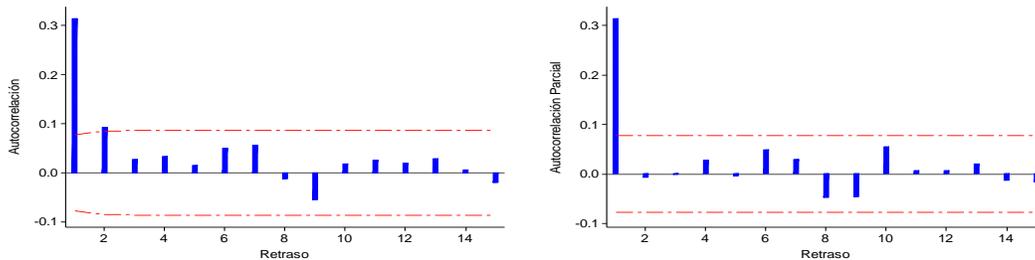


Figura 3.6. FAC y FACP de la serie transformada

El modelo para esta serie es un modelo $AR(1)$. Para la representación de este modelo en una ecuación se usa una notación especial, el cual consta de un operador ∇ que representa la diferencia para transformar la serie. En la expresión 3.4 se aprecia el modelo con la notación especial y, en la expresión 3.5 se presenta el modelo desarrollado.

3.4.2. Estimación y prueba

Para la obtención de los parámetros de cada modelo propuesto se uso nuevamente el software Minitab®, quedando las ecuaciones 3.6 y 3.7 de la serie normal y la transformada respectivamente.

La Figura 3.7 muestra los correlogramas de los residuos de cada modelo generado. El límite de significancia utilizado es del 5%. Se puede observar que los residuos de ambos modelos son ruido blanco, por lo que los dos modelos son aceptables.

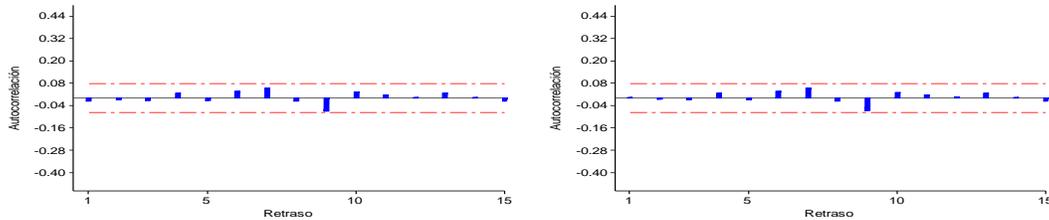


Figura 3.7. Correlogramas de residuos de los modelos $AR(2)$ y $ARIMA(1,1,0)$ respectivamente

Con las ecuaciones 3.6 y 3.7 se hace el pronóstico fuera de la muestra con los datos reservados de la muestra (110 datos que no fueron incluidos en la generación de los modelos).

3.4.3. Aplicación

Para determinar cuál de los modelos propuestos es el mejor, se hacen análisis cualitativos y cuantitativos. El primero consta de observar el comportamiento de los modelos propuestos con referencia a la serie real, mientras que el análisis cuantitativo consta de analizar los errores de los modelos por medio de medidas estadísticas presentadas en las ecuaciones 3.1 y 3.2.

En la Figura 3.8 se muestra el pronóstico fuera de la muestra de los modelos $AR(2)$ y $ARIMA(1,1,0)$ respectivamente, se observa que los dos modelos se apegan a la serie real y por lo tanto funcionan bien.

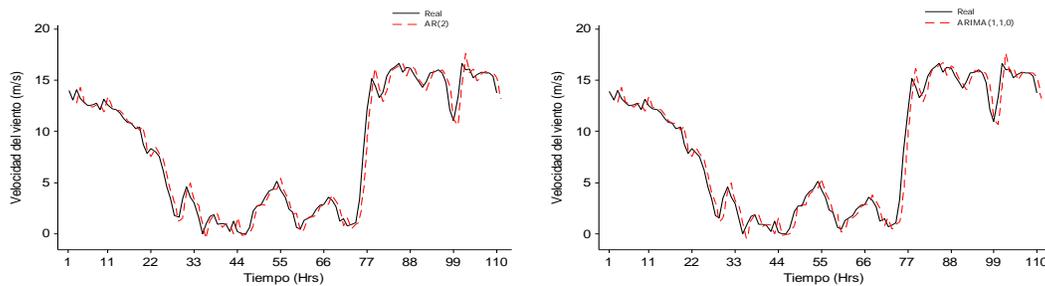


Figura 3.8. Pronóstico fuera de la muestra

El análisis cuantitativo se hace analizando los errores que cada modelo ha generado con respecto a la serie real y, para analizar los errores se recurre a las ecuaciones 3.1 y 3.2.

La Tabla 3.1 muestra los resultados del análisis de los errores. El mejor modelo es el $ARIMA(1,1,0)$, ya que presenta el error más bajo.

Tabla 3.1. Medidas de error de pronóstico

Modelo	ECM	EMA
	1.006683	0.722597
	1.034133	0.736138

3.5. Resultados y discusiones

La metodología antes presentada se aplicó a cada una de las series de la Figura 3.2, obteniendo resultados satisfactorios para el pronóstico de la velocidad del viento. En la Tabla 3.2 se muestran los modelos de cada una de las series analizadas.

Cabe mencionar que la estabilización de la media y de la varianza es aplicable según la serie de tiempo, en este tipo de series no es sencillo determinar la tendencia de la misma.

El modelo de la serie del mes de Mayo contiene una parte estacional, al observar la serie correspondiente se nota el patrón de estacionalidad por lo cual fue necesario incluirlo en el modelo.

Tabla 3.2. Modelos ARIMA para el pronóstico fuera de la muestra

Mes	Modelo	Modelo desarrollado
Enero		
Febrero		
Marzo		
Abril		
Mayo		
Junio		

En las series de tiempo analizadas en este trabajo no fue necesario estabilizar la media por diferencias, el modelo resultante trabaja de manera eficiente.

Todos los modelos se caracterizan por contar con la parte autorregresiva de la metodología ARIMA.

Los resultados indican que la metodología ARIMA funciona de manera adecuada para el pronóstico de la velocidad del viento.

Redes Neuronales Artificiales

4.1. Resumen

Las Redes Neuronales Artificiales tienen una gran variedad de aplicaciones, una de ellas es el pronóstico en series de tiempo. En este capítulo se presentan los fundamentos de las redes ADALINE y Backpropagation, ya que estos modelos se caracterizan por destacarse en el reconocimiento de patrones en series de tiempo.

4.2. Desarrollo histórico

Las primeras explicaciones teóricas sobre el cerebro y el pensamiento fueron dadas por algunos antiguos filósofos griegos, como Platón (427-347 a. C.) y Aristóteles (384-422 a. C.). Alan Turing, en 1936, fue el primero en estudiar al cerebro como una forma de ver el mundo de la computación, sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas. Ellos modelaron una red neuronal simple mediante circuitos eléctricos.

En 1957, Frank Rosenblatt comenzó el desarrollo del Perceptrón, la red neuronal más antigua, y que se usa hoy en día en varias aplicaciones como reconocedor de patrones. En 1959, Bernard Widrow y Marcial Hoff, desarrollaron el modelo ADALINE (ADAPTative LINEar Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en líneas telefónicas).

Los trabajos sobre redes neuronales fueron creciendo como fueron pasando los años, con ello, también se fueron creando nuevos modelos de redes neuronales y el mejoramiento de los primeros modelos. Uno de los mayores investigadores de las redes neuronales es Stephen Grossberg, que realizó en 1967 una red conocida como Avalancha. Por otro lado, Marvin Minsky y Seymour Papert publicaron un análisis matemático detallado del Perceptrón.

Otros investigadores que han tenido grandes aportaciones a las redes neuronales, incluso con nuevos modelos, como es el caso de James Anderson con su modelo Asociador Lineal, Kunihiko Fukushima desarrolló el Neocognitrón, y en 1982 John Hopfield presentó su trabajo de redes neuronales que describe con claridad y rigor matemático una red a la que ha dado su nombre, que es una variación del Asociador Lineal [27, 28].

Actualmente son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen y las empresas que lanzan al mercado productos nuevos,

tanto hardware como software. Las revistas que destacan en área de las redes neuronales son: *Neural Network*, revista oficial de la Sociedad Internacional de Redes Neuronales (INNS), *Network, Computation in Neural System*; *IEEE Transactions on Neural Networks*, publicada por IEEE Neural Networks Council; *Neural Computation*; e *International Journal of Neural Systems*.

4.3. Elementos de una red neuronal artificial

Las redes neuronales artificiales son modelos que intentan reproducir el funcionamiento del cerebro, averiguando cuáles son sus elementos más importantes. Una elección adecuada de sus características más una estructura conveniente, es el procedimiento adecuado para construir redes para que desarrollen determinada tarea.

Los distintos componentes de un modelo de red artificial son [29]:

- La neurona artificial: Las neuronas son las unidades que forman la red neuronal que podemos ordenar arbitrariamente. Su trabajo consiste en recibir las entradas de las unidades vecinas y calcular un valor de salida, el cual es enviado a todas las unidades restantes.
- Su estado de activación: Todas las neuronas que componen la red se hallan en cierto estado de activación. Hay dos posibles estados, reposo y excitado, y a cada uno se le asigna un valor continuo o discreto. Es necesario saber qué criterios o reglas siguen las neuronas para alcanzar tales estados de activación.
- Su función de salida y de activación: Hay un conjunto de conexiones entre las unidades o neuronas, cada una transmiten señales a las unidades conectadas a su salida que determinan el estado de activación de la neurona receptora. Existen cuatro funciones de activación: Función escalón, Función lineal y mixta, Sigmoidal y Función Gaussiana.
- Conexiones entre neuronas: Las conexiones que unen a las neuronas que forman a las redes neuronales tienen asociado un peso, que es el que hace que la red adquiera conocimiento.
- Función o regla de activación. Es una regla que combina el estado actual de la neurona para producir un nuevo estado de activación.
- Regla de aprendizaje: El aprendizaje se encuentra representado en los pesos de las conexiones entre las neuronas, se puede decir que se aprende modificando los valores de los pesos. Cada modelo dispone de sus propias técnicas de aprendizaje.

4.4. Características de las redes neuronales

Existen numerosos tipos de modelos de redes neuronales que se caracterizan por realizar tareas específicas. Las características necesarias para el pronóstico de la velocidad del viento a corto plazo son que su conexión sea solo hacia adelante, que tenga solo una neurona de salida y que su proceso de aprendizaje sea *Off Line*. Para efecto de poder

resolver dicha situación, los modelos que cumplen con estos requisitos son las redes ADALINE y Backpropagation. Otro tipo de características de las redes como son los vectores de entrada, el número de capas y el número de neuronas por capa, no se pueden definir por una regla en general.

Para definir el número de vectores de entrada se utilizan herramientas estadísticas como son la Función de Autocorrelación y la Función de Autocorrelación Parcial. En el caso del número de capas y el número de neuronas por capa, se definirán conforme se avance en la prueba de varias configuraciones de las redes neuronales.

4.4.1. Redes ADALINE

La red ADALINE fue desarrollada por Bernie Widrow en la Universidad de Stanford en 1959, La arquitectura de la red ADALINE es similar a la de la red Perceptrón, la diferencia fundamental con respecto al Perceptron es el mecanismo de aprendizaje, ADALINE utiliza el mecanismo llamada regla delta de Widrow-How o regla del mínimo error cuadrado medio basada en la búsqueda del mínimo del error entre la salida deseada y la salida lineal obtenida por el modelo.

4.4.1.1. Aprendizaje de la red ADALINE

La red ADALINE utiliza un aprendizaje *Off Line* con supervisión denominado LSM (*Least Mean Square*). Esta regla de aprendizaje es un método para hallar el vector de pesos W deseado, el cual deberá ser único y asociar con éxito cada vector del conjunto de patrones de entrada con su correspondiente valor de salida. Concretamente, la regla de aprendizaje LSM está definido como:

—

Donde n es el número de vectores de entrada (patrones) que forman el conjunto de entrenamiento, y e_k la diferencia entre la salida deseada y la obtenida cuando se introduce el patrón k -ésimo, que se expresa como sigue:

Siendo W_k la salida del Combinador Adaptativo Lineal (ALC), es decir;

El proceso de aprendizaje de una red ADALINE consta de los siguientes pasos:

- Se aplica un vector o patrón de entrada \mathbf{x} , en las entradas del ADALINE.
- Se obtiene la salida lineal con la ecuación 4.3 y se calcula la diferencia con respecto a la deseada \mathbf{d} .
- Se actualizan los pesos \mathbf{w} , en donde η es el parámetro que determina la estabilidad y la velocidad de convergencia del vector de pesos hacia el valor de error mínimo.
- Se repiten los pasos anteriores con todos los vectores de entrada \mathbf{x} .
- Si el error cuadrado medio (ecuación 4.1) es un valor reducido aceptable, termina el proceso de aprendizaje, si no, se repite otra vez todo el procedimiento.

Una de las aplicaciones de las de las redes neuronales que más pronto se pudo implementar en el campo industrial fue la ADALINE, para la eliminación de ecos en circuitos eléctricos.

4.4.2. Red Backpropagation

La red Backpropagation fue creada en 1986 por Rumelhart, Hinton y Williams, basándose en trabajos de otros investigadores, lograron un método para que una red neuronal aprendiera la asociación que existe entre los patrones de entrada a la misma y las clases correspondientes, utilizando más niveles de neuronas que los de la red Perceptron. El algoritmo de propagación hacia atrás, o retropropagación, es una regla de aprendizaje que se puede aplicar en modelos de redes con más de dos capas.

El funcionamiento de una red Backpropagation consiste en un aprendizaje de un conjunto predefinido de pares de entrada-salida dadas. El ciclo de esta red consiste en dos fases: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas posteriores hasta obtener una salida, se compara el resultado obtenido de la neurona de salida con la salida que se desea, se calcula el error para cada neurona tanto de las capas ocultas como la de salida. A continuación, estos errores se transmiten hacia atrás partiendo de la capa de salida hasta todas las neuronas de la capa oculta, este procedimiento se repite con todas las capas ocultas que contenga la red. Basándose en el valor del error recibido, se ajustan los pesos de manera que la próxima vez que se presente el mismo patrón, la salida esté más cerca de la deseada.

4.4.3. Aprendizaje de una red Backpropagation

De manera sintetizada se presentan a continuación los pasos y fórmulas a utilizar para aplicar el algoritmo de entrenamiento.

4.4.3.1. Inicialización de los pesos

Inicializar los pesos de la red con valores pequeños aleatorios.

4.4.3.2. Presentación de un patrón de entrada

Presentar un patrón de entrada, \mathbf{x} y especificar la salida deseada que debe generar la red: \mathbf{d} (si la red se utiliza como clasificador, todas las salidas deseadas serán cero, salvo una, que será a la de la clase que pertenece el patrón de entrada).

4.4.3.3. Cálculo de la salida actual de la red

Calcular la salida actual de la red, para ello se presentan las entradas a la red y se calculan las salidas que presentan cada capa hasta llegar a la capa de salida, ésta será la salida de la red \mathbf{y} . Los pasos son los siguientes:

- Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada.

Para una neurona j oculta:

En donde el índice j se refiere a magnitudes de la capa oculta (*hidden*); el subíndice i , al i ésimo vector de entrenamiento, y k a la k ésima neurona oculta. El término x_k puede ser opcional, pues actúa como una entrada más.

- Se calculan las salidas de las neuronas ocultas:
- Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida (capa n : *output*).

4.4.3.4. Cálculo de los términos de error para todas las neuronas

Si la neurona n es una neurona de la capa de salida, el valor de la delta es:

La función f debe cumplir con el requisito de ser derivable. En general se dispone de dos formas de función de salida que pueden ser de utilidad: la función lineal de salida y la función sigmoideal definida por la expresión:

La selección de la función de salida depende en la forma en se decida representar los datos de salida, si se desea que las neuronas de salida sean binarias se utiliza la función sigmoideal (ecuación 4.9). Para la función lineal, tenemos que $\delta_n = e^{-y_n}$ por lo que los términos de error para las neuronas de salida quedan:

Para el error de las capas ocultas se usa la siguiente ecuación:

4.4.3.5. Actualización de los pesos

Para ello, se utilizará el algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la siguiente forma:

- Para los pesos de la capa de salida:

- Para los pesos de la capa oculta:

- 4.4.3.6. Repetir el proceso hasta que el término error resulte aceptablemente pequeño.

—

Algunas de las aplicaciones de las RNA Backpropagation son la predicción del consumo eléctrico, gas, flujo de ríos, etc. Máquinas fotocopadoras, fallos de motores eléctricos por mencionar algunos. Sus aplicaciones son tan amplias por su facilidad de manipular un gran número de variables y por su robustez en la solución de problemas [30].

5

Pronóstico de la Velocidad del Viento Utilizando Redes Neuronales Artificiales

5.1. Resumen

En este capítulo, se presenta la generación de modelos de pronóstico de redes neuronales artificiales con series de tiempo en forma de mediciones de velocidades del viento. El entrenamiento de los modelos se realizará por medio de una aplicación desarrollada en lenguaje Delphi, así como la validación de los modelos propuestos.

5.2. Análisis de series de tiempo con Redes Neuronales Artificiales

Los fundamentos de las Redes Neuronales Artificiales (RNA) se establecieron en la década de los 1950s. Desde entonces las RNA han ganado considerable atención a causa del desarrollo de hardware y algoritmos neuronales más potentes. Las RNA han sido exploradas y estudiadas por varios investigadores, se han aplicado y manipulado en casi todos los campos de la investigación, por ejemplo, en sistemas de identificación, en el modelado, predicción y clasificación.

En la Figura 5.1 se muestran los cuatro pasos principales para el análisis de series de tiempo con RNA. Identificación del problema, preparación de los datos, modelado de RNA y el análisis de los resultados [31].

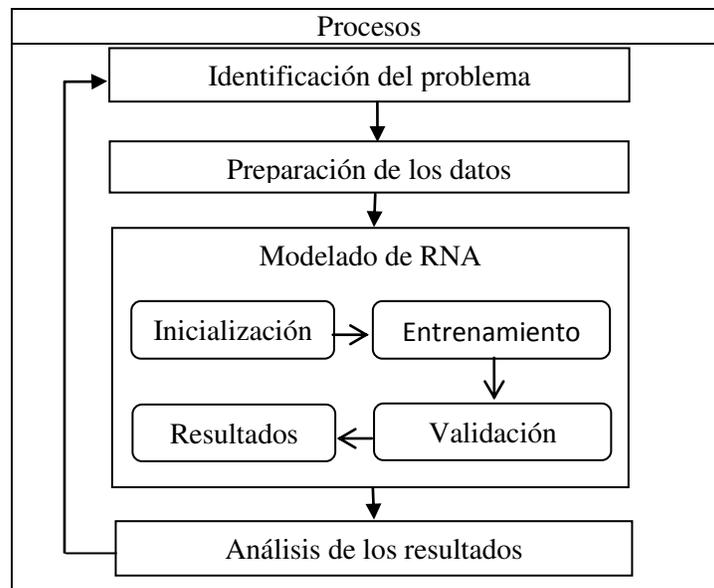


Figura 5.1. Proceso de análisis de series de tiempo con Redes Neuronales Artificiales

5.3. Preparación de los datos

La preparación de los datos es un paso importante en el modelado de series de tiempo con RNA. Los resultados del análisis previo al modelado de series de tiempo tienen una gran influencia en los resultados de los modelos de RNA, ya que la calidad de los datos de entrada a la RNA tiene gran influencia con los resultados del modelado, y el rendimiento de la RNA puede ser significativo si en los datos de entrada hay datos que faltan o se tiene distorsión en los datos.

El primer paso para la preparación de los datos es la inspección. El objetivo de la inspección es detectar problemas en la serie de tiempo. La inspección de los datos se hace de manera cuantitativa y cualitativa, la primera se hace por medio de la observación, en donde se pueden encontrar dos problemas en general, que el tamaño de los datos o la muestra sea muy grande o muy pequeña. La inspección cualitativa de los datos puede ser realizada por métodos estadísticos en los que se puede determinar la falta de datos, escala y tendencia en los datos y, la no estacionariedad.

Si el número de datos o la muestra son muy grandes, es necesario obtener una muestra representativa. Una manera efectiva de hacerlo es dividiendo la muestra en varios grupos de datos. Por otra parte, si la muestra es muy pequeña es necesario volver a recolectar más datos para complementar los datos que se tenían. La falta de datos en la serie de tiempo es un problema que se puede solucionar por medio de la reparación de los datos, esto se hace basándose en los datos originales recuperando datos faltantes. Otra opción es estimar los datos faltantes usando los datos existentes asumiendo que hay una correlación entre los datos faltantes y los datos que se tienen.

En el aprendizaje de las RNA, los datos con diferentes escalas a menudo conducen a la inestabilidad de la RNA. La escala usada para los datos de entrada de la RNA usualmente va de 0 a 1[32]. Un método lineal para normalizar los datos es usando la ecuación 5.1.

En donde x es el valor correspondiente de la variable, x_{\min} es el valor mínimo de dicha variable, y x_{\max} es el valor máximo para la variable de la serie de datos. En la Figura 5.2 se presenta la serie de tiempo normalizada que será usada para el entrenamiento de los modelos ADALINE y Backpropagación.

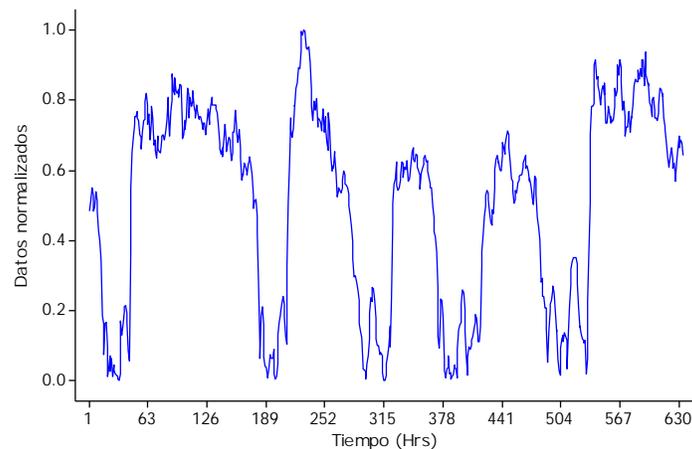


Figura 5.2. Serie de tiempo normalizada

Para la predicción con RNA, la presencia de tendencia en los datos tiene efectos no deseables en el rendimiento de la predicción. Similarmente, investigadores han demostrado que la estacionalidad tiene un impacto significativo en la predicción. En el análisis de series de tiempo univariadas la no estacionariedad es un problema para este análisis. Para resolver dichas situaciones un método muy usado es la diferencia de los datos para estabilizar la media respecto del tiempo.

5.4. Entrenamiento de modelos ADALINE

El entrenamiento de los modelos ADALINE se hace por medio de un método intuitivo denominado método iterativo. En la Figura A1.1 del Anexo 1 se muestra el diagrama de flujo para el entrenamiento de una red ADALINE.

La secuencia del diagrama de la Figura A1.1 del Anexo 1 es la siguiente: Primero se introduce un parámetro de entrenamiento de la red, el siguiente paso es iniciar los pesos con un valor pequeño aleatorio, para este caso se usará el valor de 0.5, se calcula la salida lineal de la red y se calcula la diferencia con respecto a la salida deseada, con esto termina la inicialización de la red. El primer ciclo del diagrama se encarga de terminar el entrenamiento de la red tomando en cuenta todos los parámetros de entrenamiento, hasta este punto la red se ha entrenado con un solo valor para el parámetro de convergencia. El segundo y el tercer ciclo buscan el parámetro de convergencia con el cual se tenga el error de entrenamiento más pequeño. Este proceso se repite el número de veces n , que es el número de veces que se va a entrenar la red. Para determinar el número de veces que la red será entrenada se toma como referencia la estabilización del error de entrenamiento, esto quiere decir que conforme el número de entrenamientos vaya aumentando la diferencia entre el error de entrenamiento en t con respecto al error en $t-1$ sea muy pequeña, y que por supuesto el error no vaya en aumento.

El entrenamiento se puede realizar en Excel, pero uno de los inconvenientes es que aquí se tienen que escribir todas las ecuaciones que implica el modelo de RNA, el otro inconveniente es que cuando la red se entrena más de 20 veces, el tiempo que tarda en hacer los cálculos tarda más de 10 segundos, lo que quiere decir que para buscar el parámetro de convergencia de la red con incrementos pequeños, como recomienda el autor [29], en muchos de los casos el proceso tiene que repetirse más de 100 veces, el tiempo que se tarda Excel en terminar el proceso de convergencia con 100 intentos de convergencia es de un poco más de 16 minutos, esto es para un solo modelo. Por lo general se hacen varios experimentos para encontrar el mejor modelo de RNA.

Debido a los inconvenientes mencionados en el párrafo anterior, se desarrolló un programa que fuera capaz de llevar el proceso de entrenamiento y de validación de los modelos ADALINE y Backpropagation, con el cual se reducen los tiempo de entrenamiento de manera considerable tomando en cuenta que en Excel se tarda más de 16 minutos en llegar a la convergencia del error de entrenamiento el programa tarda menos de 5 segundos en llegar a la convergencia.

El funcionamiento del programa es idéntico a la metodología de entrenamiento de las redes ADALINE y Backpropagation, en donde se toma la función para el cálculo de la salida de la red como una función lineal, y sigue el mismo proceso que el diagrama de flujo de la Figura A1.1 del Anexo 1. La entrada de los parámetros de entrenamiento se hace copiando los datos directamente de un archivo de Excel, la configuración de la topología de la red es definida por el usuario, así como el número de entrenamientos de la red, en el Anexo 2 se muestra una descripción breve del programa.

Los modelos ADALINE que se proponen son los siguientes:

- Modelo 1: dos capas, dos vectores de entrada y un vector de salida (el valor que se desea pronosticar).

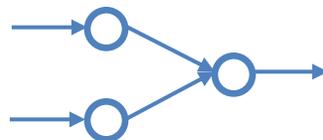


Figura 5.3. Modelo 1 (RNA-2C-2VE)

- Modelo 2: dos capas, tres vectores de entrada y un vector de salida (el valor que se desea pronosticar).

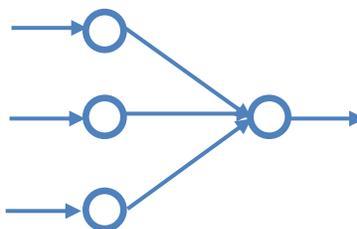


Figura 5.4. Modelo 2 (RNA-2C-3VE)

El entrenamiento de la red se hizo con el 85% de la serie de tiempo que se presenta en la Figura 5.2. El 15% de los datos se usarán para validar los modelos propuestos por medio de las medidas estadísticas de error que se presentaron en el capítulo 3 (ecuaciones 3.1 y 3.2).

En la Tabla 5.1 se muestra la evolución del error de entrenamiento conforme aumenta el número de iteraciones () con su respectivo incremento (factor de convergencia). El cambio del error de la iteración 175 a la 200 es muy pequeño, tanto que la diferencia se aprecia hasta la quinta cifra después del punto decimal, por lo que los experimentos con los modelos propuestos se harán a 200 iteraciones.

Tabla 5.1. Errores de entrenamiento del modelo 1

Iteraciones	Incremento	Error
1	0.471	0.00173239
25	0.211	0.00124340
50	0.153	0.00118725
75	0.125	0.00116238
100	0.109	0.00114754
125	0.097	0.00113738
150	0.089	0.00112987
175	0.082	0.00112402
200	0.077	0.00111929

El entrenamiento de los modelos propuestos arrojó los resultados de la Tabla 5.2. El mejor modelo con el error de entrenamiento más pequeño es el modelo 1 (RNA-2C-2VE).

Tabla 5.2. Error de entrenamiento ADALINE

Modelo	Iteraciones	Incremento	Error
RNA-2C-2	200	0.077	0.00111929
RNA-2C-3	200	0.069	0.00114366

5.5. Validación ADALINE

Para la validación de los modelos ADALINE propuestos se harán dos tipos de análisis. El primero es el análisis cualitativo, el cual consiste en comparar en una gráfica los datos de validación (el 15% de la serie) con los datos generados por los modelos propuestos. En la Figura 5.5 se muestran los datos de validación con los datos de los modelos propuestos, se observa que ambos modelos siguen a la serie de validación.

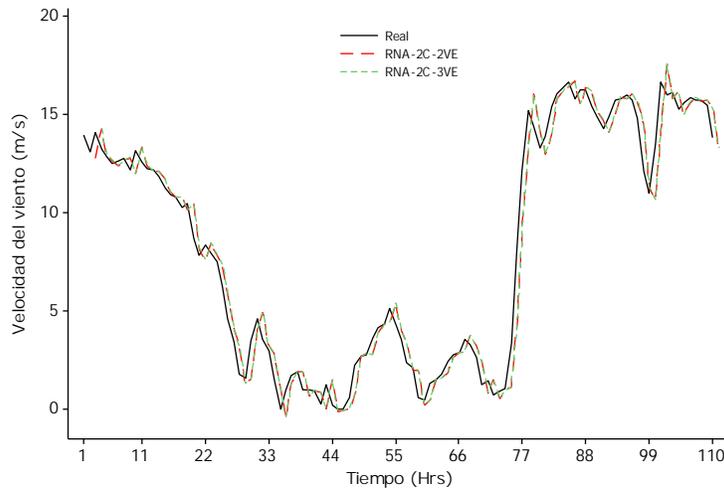


Figura 5.5. Pronóstico fuera de la muestra ADALINE

El análisis cuantitativo se hace por medio de las medidas estadísticas de error que se usaron en el capítulo 3 (ecuaciones 3.1 y 3.2). En la Tabla 5.3 se muestra que el mejor modelo es el modelo 2 que contiene los errores más pequeños.

Tabla 5.3. Medidas estadísticas de error ADALINE

Modelo	ECM	EMA
RNA-2C-2	1.02073	0.7259
RNA-2C-3	1.01538	0.71767

5.6. Entrenamiento Backpropagation

De manera similar, el proceso de entrenamiento de una RNA Backpropagation se lleva a cabo en tres pasos principales, inicialización, actualización de los pesos y encontrar el punto o parámetro de convergencia. El entrenamiento de este modelo es un poco más complicado por el simple hecho de tener capas ocultas, si se hiciera un diagrama de flujo como el de la Figura A1.1 del Anexo 1, se tendría que agregar un ciclo para el número de capas ocultas y otro ciclo anidado con el anterior para el número de neuronas de cada capa oculta. El tiempo de cálculo de una RNA Backpropagation es mucho más que el de una red ADALINE ya que se incrementa el número de neuronas a calcular.

Los modelos propuestos para la RNA Backpropagation son los siguientes:

- Modelo 3: Tres capas, dos vectores de entrada, tres neuronas ocultas en su capa oculta, y un vector de salida (valor que se desea pronosticar).

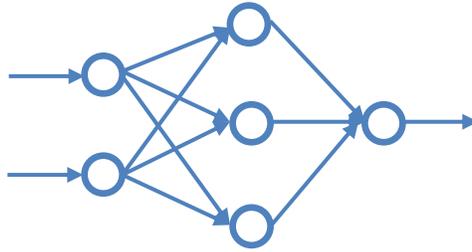


Figura 5.6. Modelo 3 (RNA-3C-2-3)

- Modelo 4: Tres capas, dos vectores de entrada, cuatro neuronas ocultas en su capa oculta, y un vector de salida (valor que se desea pronosticar).

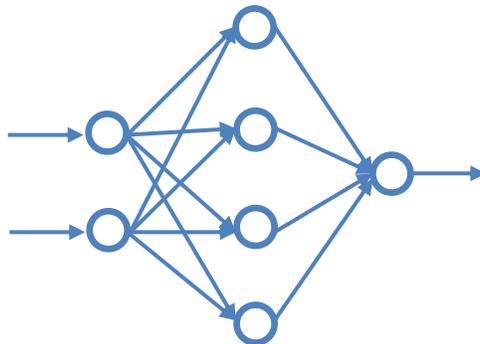


Figura 5.7. Modelo 4 (RNA-3C-2-4)

- Modelo 5: Cuatro capas, dos vectores de entrada, tres neuronas en la primera capa oculta, dos neuronas en la última capa oculta, y un vector de salida (valor que se desea pronosticar).

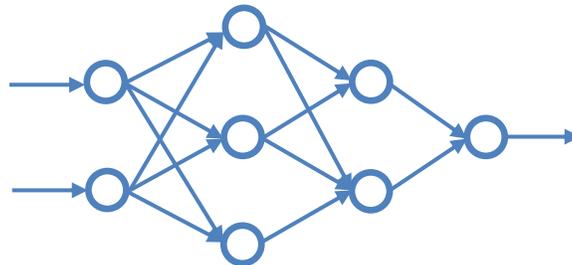


Figura 5.8. Modelo 5 (RNA-4C-2-3-2)

Los modelos 3, 4 y 5 fueron propuestos por presentar los errores de entrenamiento más pequeños. En la Tabla 5.4 se muestra la evolución del error del modelo 3, por lo que se seguirán entrenando los modelos a doscientas iteraciones ya que se tiene un cambio del error muy pequeño.

Tabla 5.4. Error de entrenamiento del modelo 3

Iteraciones	Incremento	Error
1	0.234	0.00187189
25	0.091	0.00129449
50	0.066	0.00122360
75	0.055	0.00119222
100	0.048	0.00117352
125	0.043	0.00116073
150	0.039	0.00115128
175	0.036	0.00114392
200	0.034	0.00113798

La Tabla 5.5 muestra los resultados del entrenamiento de los modelos Backpropagation. El mejor modelo con los errores más pequeños es el modelo 5, el cual está configurado con dos vectores de entrada, tres neuronas en la primera capa oculta, dos neuronas en la última capa oculta y su respectivo vector de salida.

Tabla 5.5. Error de entrenamiento Backpropagation

Modelo	Iteraciones	Incremento	Error
RNA-3C-2-3	200	0.034	0.00113798
RNA-3C-2-4	200	0.026	0.00113794
RNA-4C-2-3-2	200	0.016	0.00113709

5.7. Validación Backpropagation

De la misma manera que se validaron los modelos ADALINE se hará con los modelos Backpropagation, esto es, un análisis cualitativo y cuantitativo. En la Figura 5.9 se muestra el pronóstico fuera de la muestra de los modelos propuestos. Se observa que los modelos siguen los parámetros de los datos de validación (el 15% de la serie de muestra).

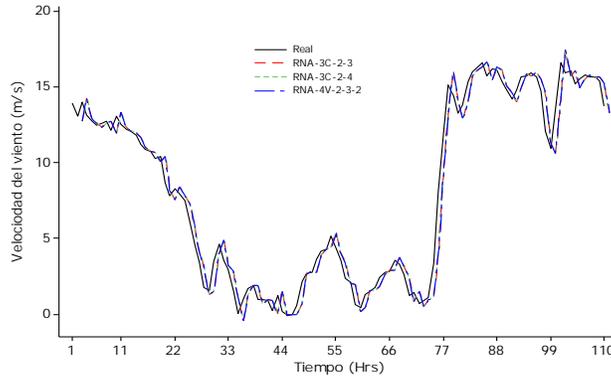


Figura 5.9. Pronóstico fuera de la muestra Backpropagation

El análisis cuantitativo se hace con las ecuaciones 3.1 y 3.2. En la Tabla 5.6 se muestran los resultados del análisis de los modelos por medio de las medidas estadísticas de error (ECM y EMA).

Tabla 5.6. Medidas estadísticas de error Backpropagation

Modelo	ECM	EMA
RNA-3C-2-3	1.02694	0.72771
RNA-3C-2-4	1.02703	0.72775
RNA-4C-2-3-2	1.02749	0.72771

En el análisis de los errores de entrenamiento se concluyó que el modelo con errores más pequeños es el modelo 5. En la Tabla 5.6 se demuestra por medio del pronóstico fuera de la muestra y con las medidas estadísticas de error que el mejor modelo es el modelo 3 ya que presenta los errores de pronóstico más pequeños de todos los modelos propuestos de RNA Backpropagation. Lo que interesa es que el modelo tenga errores de pronóstico pequeños, así que se tomará el modelo 3 como el mejor modelo Backpropagation.

5.8. Comparación ADALINE con Backpropagation

Los resultados que arrojaron los modelos ADALINE y Backpropagation en su validación se resumen en la Tabla 5.7. El modelo que presenta errores de pronóstico más pequeños es el modelo ADALINE (Modelo 1). El modelo 1 es el que se usará para determinar qué metodología es mejor para el pronóstico de la velocidad del viento a corto plazo.

Tabla 5.7. Medidas estadísticas de error ADALINE y Backpropagation

Modelo	ECM	EMA
RNA-2C-3	1.01538	0.71767
RNA-3C-2-3	1.02694	0.72771

5.9. Resultados y discusiones RNA

La metodología usada en el ejemplo anterior para determinar el mejor modelo para el pronóstico de la velocidad del viento a corto plazo, se usó para el entrenamiento de los modelos para las series de tiempo de la Figura 3.2 del capítulo 3. Los resultados del entrenamiento y validación de los modelos propuestos para cada una de las series de tiempo se muestran en la Tabla 5.8.

Tabla 5.8. Resumen de modelos de RNA

Mes	Modelo	ECM	EMA
Enero	RNA-2C-3	1.01538	0.71767
Febrero	RNA-2C-2	0.77335	0.64732
Marzo	RNA-2C-3	0.87001	0.68626
Abril	RNA-3C-3-2	0.46548	0.53739
Mayo	RNA-2C-3	2.55413	1.0819
Junio	RNA-3C-3-2	1.43873	0.79557

El modelo que presenta errores más pequeños es el modelo del mes de Abril, esto no significa que sea el mejor de todos, ya que todas las series de tiempo son diferentes.

Para la series de tiempo del mes de Abril y Junio los modelos Backpropagation son los modelos que presentaron errores de pronóstico más pequeños. Para las demás series de tiempo los mejores modelos son ADALINE de dos y tres vectores de entrada.

Los modelos de las series de tiempo de Abril y Junio son modelos más complicados que los modelos de las series restantes, pero esto no significa que cuanto más complicado es el modelo más preciso para el pronóstico de la velocidad del viento a corto plazo.

El porcentaje de error de pronóstico más pequeño corresponde al modelo generado con la serie de tiempo del mes de Febrero con un 7.58% de error, esto se debe a que el promedio (8.532) de los datos de validación, es el promedio más grande de todas las series de validación.

El modelo que generó el mayor porcentaje de error es el modelo generado con la serie de tiempo del mes de junio con un 26.2%. El promedio que correspondiente a los datos de validación es de 3.036 el cual es el promedio menor de todas las series de validación.

6

Comparación de los Modelos ARIMA y RNA

6.1. Resumen

En los capítulos anteriores se han desarrollado modelos Autorregresivos y de inteligencia artificial, por medio de herramientas estadísticas se ha obtenido el mejor modelo en función de los errores de pronóstico, para pronosticar la velocidad del viento a corto plazo. En esta sección se comparan los modelos resultantes de cada una de las metodologías para determinar cuál de las dos metodologías funciona mejor.

6.2. Comparación de modelos

Los resultados de la metodología ARIMA para el pronóstico de la velocidad del viento se presentaron en el capítulo 3 en la Tabla 3.2 para todas las series de tiempo. En la Tabla 5.8 del capítulo 5 se tienen los resultados del modelado de series de tiempo para el pronóstico de la velocidad del viento a corto plazo. Ahora, en la Tabla 6.1 se muestran los modelos resultantes de la metodología ARIMA y RNA con sus respectivas medidas estadísticas de error.

Tabla 6.1. Modelos ARIMA y RNA

Mes\Modelo	ARIMA			RNA		
	MODELO	ECM	EMA	MODELO	ECM	EMA
Enero	AR(2)	1.00668	0.72260	RNA-2C-3	1.01538	0.71767
Febrero	AR(2)	0.76058	0.64484	RNA-2C-2	0.77335	0.64732
Marzo	AR(2)	0.85878	0.68195	RNA-2C-3	0.87001	0.68626
Abril	AR(2)	0.47607	0.54961	RNA-3C-3-2	0.46548	0.53739
Mayo	SARIMA(2,0,0)(0,0,1) ₁₃	2.54765	1.09408	RNA-2C-3	2.55413	1.08190
Junio	AR(2)	1.44342	0.80580	RNA-3C-3-2	1.43873	0.79557

2C=Número de capas.

* Los números que aparecen después del número de capas representa las neuronas en cada capa.

De la Tabla 6.1 se concluye que para las series de tiempo de Enero, Abril, Mayo y Junio, los modelos de RNA son los que presentan errores de pronóstico fuera de la muestra más pequeños. En algunos casos son solo mejores las RNA en el promedio de los errores (EMA) y en otros casos como en Abril y Junio son completamente mejores. Los modelos con errores más bajos se marcaron con sombreado gris para poder identificarse.

6.3. Resultados y discusiones

Los modelos resultantes de las dos metodologías (ARIMA y RNA) se numeran a continuación:

- Enero: Modelo ADALINE RNA-2C-3.

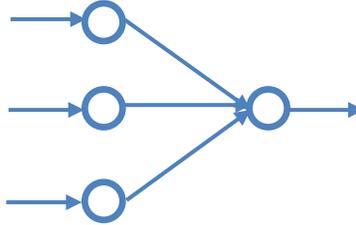


Figura 6.1. Mejor modelo para la serie de tiempo de Enero

Tabla 6.2. Valores de los pesos Enero

No. Del peso	Valor del peso
w_1	1.28190203
w_2	-0.28341877
w_3	-0.00020922

- Febrero: Modelo
 - Ecuación:

- Marzo: Modelo
 - Ecuación:

- Abril: Modelo Backpropagation RNA-3C-3-2.

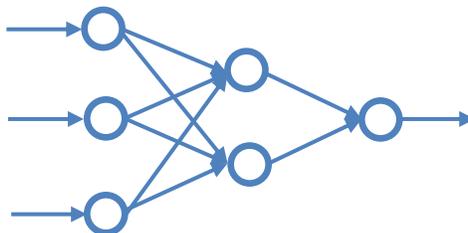


Figura 6.2. Mejor modelo para la serie de tiempo de Abril

Tabla 6.3. Valores de los pesos Abril

No. Del peso	Valor del peso
w_1	1.22073205
w_2	1.22073205
w_3	-0.35763864
w_4	-0.35763864
w_5	-0.00127422
w_6	-0.00127422
w_7	0.56390243
w_8	0.56390243

➤ Mayo: Modelo ADALINE RNA-2C-3.

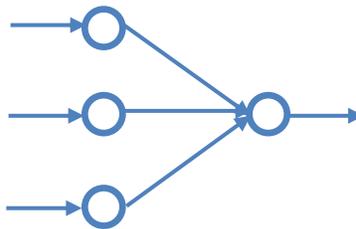


Figura 6.3. Mejor modelo para la serie de tiempo de Mayo

Tabla 6.4. Valores de los pesos Mayo

No. Del peso	Valor del peso
w_1	1.22071946
w_2	-0.19436533
w_3	-0.07005557

➤ Junio: Modelo Backpropagation RNA-3C-3-2.

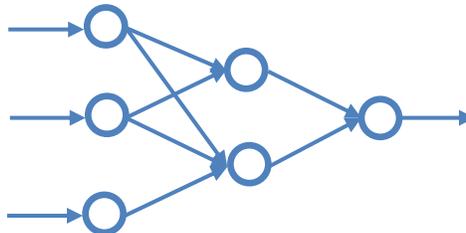


Figura 6.4. Mejor modelo para la serie de tiempo de Junio

Tabla 6.5. Valores de los pesos Junio

No. Del peso	Valor del peso
w_1	1.05239900
w_2	1.05239900
w_3	-0.13442337
w_4	-0.13442337
w_5	0.00210512
w_6	0.00210512
w_7	0.51712428
w_8	0.51712428

Para decidir el mejor modelo para las series de tiempo de Enero y Mayo se tomó en cuenta el Error Medio Absoluto, ya que esta medida de error representa el promedio del error de pronóstico.

La diferencia de los errores de las series de tiempo de los meses de Febrero, Marzo, Abril y Junio es de centésimas. Tanto los modelos ARIMA y de RNA pueden ser usados para el pronóstico de la velocidad del viento a corto plazo.

Con el número de datos de validación se demuestra que los modelos funcionan hasta por 100 horas sin tener que actualizarlos, esto es, sin tener que volverlos a entrenar.

El porcentaje de error más pequeño sigue siendo del modelo entrenado con la serie de tiempo del mes de Febrero con el 7.55% cuya diferencia es de centésimas con respecto al modelo de RNA. El porcentaje de error más alto que se tiene es para el modelo generado con RNA para el mes de Junio con el 26.2%.

Los errores más grandes que se tuvieron en el pronóstico fuera de la muestra se deben al comportamiento aleatorio de la velocidad del viento, y es por eso que se tienen porcentajes de error tan grandes.

La eficiencia de las metodologías depende del tipo de series de tiempo que se analicen. Además, el comportamiento de las series de tiempo es un factor importante para la generación de modelos de pronóstico a corto plazo.

Para los modelos de RNA, no necesariamente la complejidad de los modelos tiene que ver con la obtención de mejores resultados como es el caso de los modelos generados con las series de tiempo de los meses de Abril y Junio.

En el capítulo 5 se demostró que el número de entrenamientos (iteraciones) es factor importante para el buen funcionamiento del modelo, esto es, porque el modelo reconoce el mayor número de patrones que pueda contener la serie de tiempo.

El tiempo de entrenamiento de una RNA en Excel es muy grande, puede ir de pocos segundos hasta más de 15 min. Es por eso que la programación es una herramienta

indispensable para el entrenamiento de RNA. Los tiempos de entrenamiento por el programa desarrollado para el pronóstico de la velocidad del viento son de menos de un minuto para 200 iteraciones.

Los modelos ARIMA y RNA pueden ser usados para el pronóstico de la velocidad del viento a corto plazo.

Conclusiones

Los objetivos planteados en este trabajo se han cumplido en su totalidad, se han generado modelos de pronóstico de la velocidad del viento a corto plazo en forma horaria para cada una de las muestras con las que se cuentan.

Queda demostrado que las técnicas ARIMA y RNA trabajan de manera eficiente con series de tiempo en forma de velocidades del viento en el modelado de pronóstico a corto plazo.

Los modelos generados han sido evaluados con medidas de error estadísticas para la correcta comparación de las técnicas ARIMA y RNA. De la misma manera, se puede plantear la aplicación de dichos modelos para series de tiempo de otra naturaleza.

La preparación de los datos previa al análisis con RNA es determinante para la obtención de buenos resultados en el pronóstico de la velocidad del viento a corto plazo.

Bibliografía

- [1] **Global Wind Energy Council.** GWEC. [En línea] Global Wind Energy Council. [Citado el: 20 de Mayo de 2010]
<http://www.gwec.net/index.php?id=119>
- [2] **ARIMA vs. Neural Networks for Wind Speed Forecasting.** Palomares-Salas J.C., y otros. Hong Kong, China. Print ISBN: 978-1-4244-3819-8, May 2009
- [3] **World Wind Energy Association.** World Wind Energy Report 2009. Istanbul : REDBlades, 2010
- [4] **Energía Alimarket.** Acciona Energía finaliza un parque eólico en México con una potencia de 250 MW. 24 de Noviembre de 2009. [Citado el: 20 de Mayo de 2010]
<http://www.alimarket.es/alimarket-portal/noticia/21239/Acciona-Energia-finaliza-un-parque-eolico-en-Mexico-con-una-potencia-de-250-MW>
- [5] **Global Wind Energy Council.** Global Wind Energy Council. [Citado el: 20 de Mayo de 2010]
<http://www.gwec.net/index.php?id=119>
- [6] **ARIMA Time Series Application to Employment Forecasting.** Xiaoguo Wang y Yuejing Liu. s.l. : 4th International Conference on Computer Science & Education. 2009
- [7] **CUSTOMER SHORT TERM LOAD FORECASTING BY USING ARIMA TRANSFER FUNCTION MODEL.** M.Y. Cho, J.C. Hwang y C.S. Chen. 2009. 95TH8130 0-7803-2981
- [8] **Research on wind power forecasting method using phase space reconstruction and artificial neural network.** Minghao Zhao, Dongxiang Jiang y Chao Liu. Beijing : s.n
- [9] **Forecast of Wind Speed and Power of Wind Generator based on Pattern Recognition.** Zhou Hui, Huang Mei y Wu Xinfhua. 2009
- [10] **Meteorología y Clima.** Castillo M., Casas Carmen y Jordán Marta Alarcón. Barcelona : Ediciones UPC, 1999. págs. 13-84. 84-8301-355-X
- [11] **Performance Test Code for Wind Turbines.** ASME. ASME/ANSI PTC 42-1988. American Society of Mechanical Engineers. New York (1989)

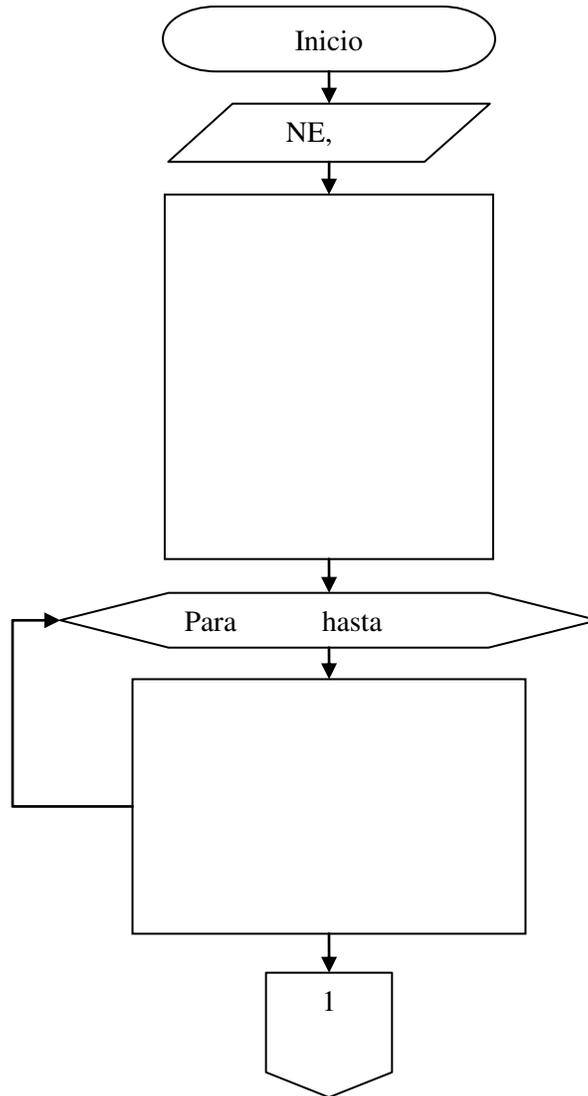
- [12] **Wind Energy Explained Theory, Design and Application.** Manwel J.F., McGowan J.G. y Rogers A.L. Amherst : John Wiley & Sons Ltd. 2002. págs. 21-81. 0-470-84612-7
- [13] **Wind and Solar Power Systems.** Mukund R. Patel. CRC Press. New York 1999. 351 pp
- [14] **WIND ENERGY Renewable Energy and the Environment.** Nelson Vaughn. s.l. : CRC Press. 2009. 978-1-4200-7568-7
- [15] **Energía renovable práctica.** Iñaki y Lus, Sebastián Urkia. Navarra : PAMIELA, 2003. 84-7681-375-9
- [16] **Wind and Solar Power Systems Diseño, Analysis, and Operation.** Patel Mukund R. Second Edition. New York : Taylor & Francis Group. 2006. págs. 25-60. 0-8493-1570-0
- [17] **Crespo, Emiliano.** www.mexicohazalgo.org.mx. [En línea] 10 de Marzo de 2010. [Citado el: 13 de Mayo de 2010]

<http://www.mexicohazalgo.org.mx/2010/03/en-2011-entrarn-en-operacin-3-nuevos-parques-elicos-en-oaxaca/>
- [18] **Introduction to Time Series Analysis and Forecasting with applications of SAS and SPSS.** Yaffee Robert y Mcgee Monie. New York : ACADEMIC PRESS, INC. 2000. págs. 69-150
- [19] **Forecasting With Univariate Box- Jenkins Models CONCEPTS AND CASES.** PANKRATZ ALAN. New York : John Wily & Sons Inc. 1983. págs. 8-9. 0-471-09023-9
- [20] **Introduction to Time Series and Forecasting.** Peter J. Brockwell, Richard A. Davis. Second Edition. New York : Springer, 2002
- [21] **Time Series Analysis and Its Applications With R Examples.** Shumway Robert H. y Stoffer David S. Second Edition. New York : Springer Science Business Media, LLC. 2006. págs. 84-165. 10: 0-387-29317-5
- [22] **Statistical Methods for Forecasting.** Abraham Bovas y Ledolter Johannes. New Jersey : John Wiley & Sons, Inc. 2005. págs. 281-321. 13 978-0-471-76987-3
- [23] **TIME-SERIES FORECASTING.** Chatfield Chris. New York : CHAPMAN & HALL/CRC. 2000. 1-58488-063-5

- [24] **Distribution of the Serial Correlation Coefficients.** Anderson R. L. s.l. : Annals of Mathematical Statistics. 1942
- [25] **The Joint Distribution of Serial Correlation Coefficients.** Quenouille M. H. s.l. : Annals of Mathematical Statistics. 1949
- [26] **Time Series Analysis Forecasting and Control.** Box Geroge E. P., Jenkins Gwilym M. y Reinsel Gregory C. Third Edition. New Yersey : Prentice-Hall, Inc. 1994. 0-13-060774-6
- [27] **FUNDAMENTALS OF NEURAL NETWORK MODELING: NEUROPSYCHOLOGY AND COGNITIVE NEUROSCIENCE.** Parks Randolph W., Levine Daniel S. y Long Debra L. Massachusetts : Massachusetts Intitute of Technology. 1998. 0-262-16175-3
- [28] **An Introduction to Neural Networks.** Krose Ben y van der Smagt Patrick. Eighth Edition. Amsterdam : The University of Amsterdam. 1996
- [29] **Redes Neuronales Artificiales; Fundamentos, Modelos y aplicaciones.** Hilera González José Ramon y Martínez Hernando Víctor José. D. F. : Alfaomega. 2000. 958-682-172-2
- [30] **Redes Nueroales y Sistemas Borrosos.** Martin del Brio Bomifacio y Sanz Molina Alfredo. Tercera edición. México 2007. Editorial Alfaomega. ISBN 978-970-15-1250-0.
- [31] **FOREIGN-EXCHANGE-RATE FORECASTING WITH ARTIFICIAL NEURAL NETWORKS.** Lean YU, Shouyang WANG and Kin Keung LAI. Springer Science Business Media, LLC. 2007. ISBN-13: 978-0-387-71719-7
- [32] **Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering.** Nikola K. Kasabov. Massachusetts Institute of Technology. 1996. ISBN 0-262-11212-4

Anexo 1

Diagrama de flujo para el entrenamiento de una red ADALINE.



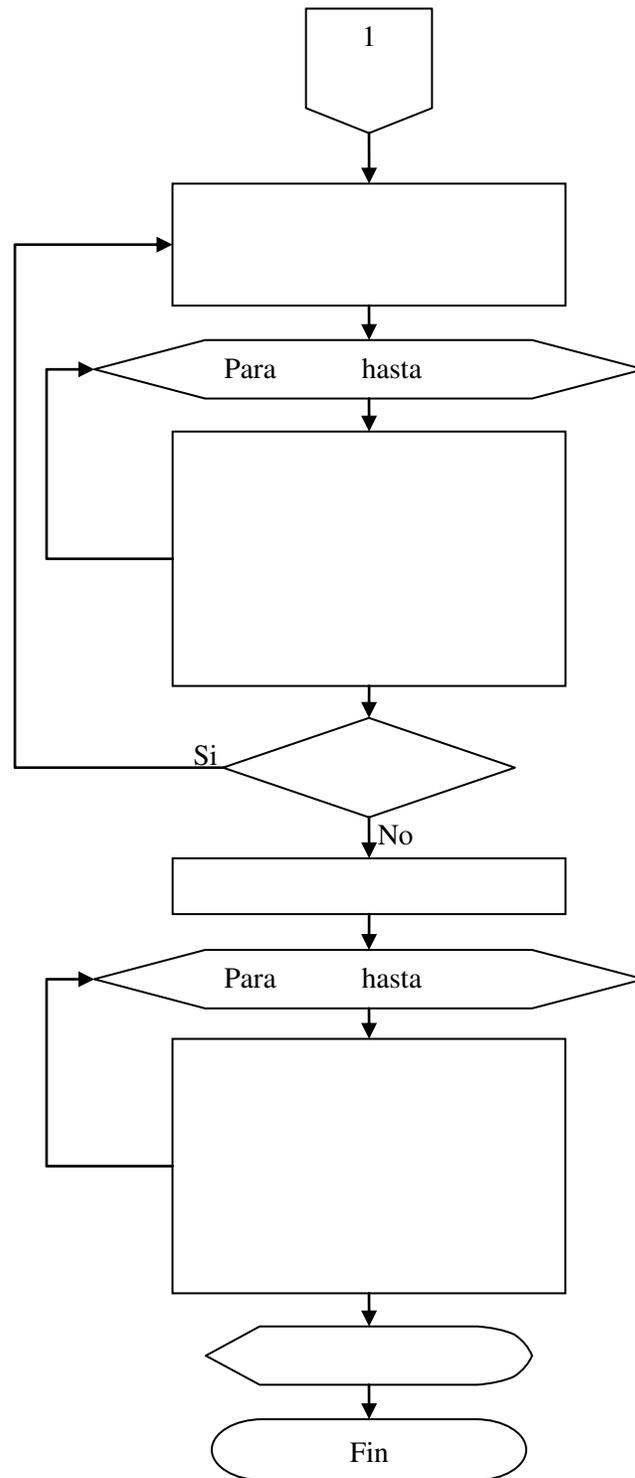


Figura A1.1 Diagrama de flujo ADALINE

Anexo 2

A continuación se presenta un tutorial para el entrenamiento de una RNA ADALINE y Backpropagation para el pronóstico de la velocidad del viento a corto plazo. En la Figura A2.1 se presenta la ventana principal del programa *Adaline y BP*. Se compone de tres partes: un menú para las diferentes opciones del entrenamiento de la RNA que va desde ingresar los datos hasta ver los resultados de validación, un panel donde se registra todo lo que se hace en el programa y una tabla para ingresar los datos para entrenar la RNA.

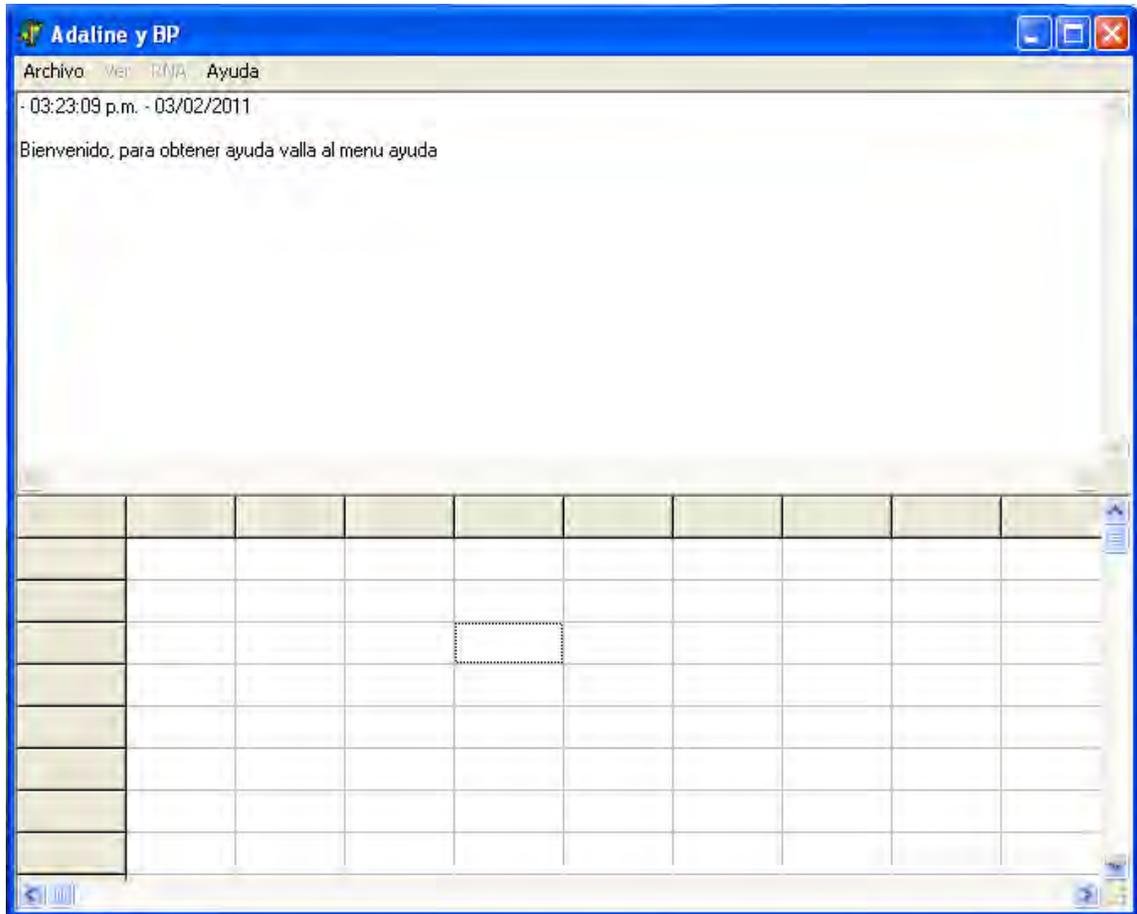


Figura A2.1 Ventana principal

El programa fue diseñado para que el usuario evite errores como el tratar de entrenar la red sin haber ingresado los datos. A continuación se presenta una serie de pasos para la correcta utilización del programa.

a) Importación de la serie de tiempo

El ingreso de la serie de tiempo con que se desea entrenar el modelo de RNA se puede hacer con las siguientes opciones:

- Desde el menú *Archivo-Imp. Datos*.
- Presionando las teclas *Ctrl+v*.
- Con el clic derecho en el menú *pegar*.

Todas las opciones anteriores funcionan de igual manera, toman los datos del portapapeles de Windows y los pegan en la tabla de la parte inferior del programa.

Nota: se debe tener cuidado con el ingreso de los datos ya que el programa no está configurado para detectar espacios ni letras y omitirlos, solo tiene un filtro para que se ingrese texto.

b) Configuración de la RNA

Una vez que se introdujeron los datos se precede a configurar la RNA por medio del menú *RNA-Conf. Red*, se despliega una ventana en donde se puede escribir el número de vectores de entrada, el número de capas y el número de neuronas por capa oculta. Además, en la parte inferior izquierda se introduce el número de datos para la parte de validación. En la Figura A2.2 se muestra la ventana de configuración de red.

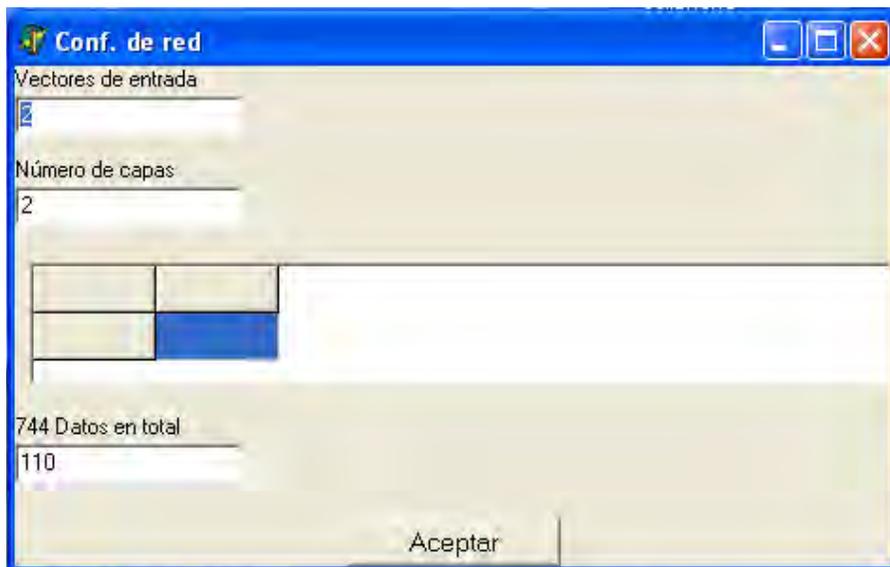


Figura A2.2 Ventana configuración de red

c) Entrenamiento de la RNA

Una vez que se han ingresado los datos, se ha configurado la RNA y se han establecido cuantos datos se manejarán en la validación del modelo se procede al entrenamiento de la

misma. En el menú *RNA-Entrenar* se despliega una ventana en donde se puede definir el número de entrenamientos ó iteraciones y el parámetro de convergencia ó incremento. Al dar clic en el botón *entrenar* se entrena la RNA según su configuración, después se da clic en el botón *Buscar red* para encontrar el parámetro de convergencia para el cual el error de entrenamiento es más pequeño. Con esto hemos entrenado un modelo de RNA.

d) Mostrar resultados de validación

Ahora en el menú *RNA-Pronosticar* Se muestra una tabla con la información de configuración de la red, de entrenamiento de la red y las medidas de error estadísticas del pronóstico fuera de la muestra.

En el menú *Ver-Pronostico* se muestra una gráfica en donde se comparan los datos reales y los datos generados por el modelo. En el menú *Ver-Pesos* se muestran los pesos de la red entrenada y para ver la evolución del error de entrenamiento es en menú *Ver-Error de entrenamiento* en donde se despliega una gráfica del error de entrenamiento.

e) Exportar resultados

Para llevar los resultados a un software de procesamiento de texto o a una hoja de cálculo se hace de la siguiente manera:

- Se puede seleccionar solo las tablas ó texto de interés, dar clic derecho y en la opción de *copiar* para mandar los datos al portapapeles de Windows, de esta manera se puede pegar en cualquier otro lado.
- En el menú *Archivo-Exp. Datos* selecciona toda la información del panel y la envía al portapapeles.
- Para copiar las gráficas se solo se tiene que dar clic derecho sobre las mismas y en la opción *copiar* se manda la gráfica como imagen al portapapeles de Windows.