UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
Departamento de Ingeniería Mecánica

D. JOSE MANUEL QUINTANA SANTANA SECRETARIO DEL DEPARTAMENTO DE INGENIERIA MECANICA DE LA UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA,

CERTIFICA,

Que el Consejo de Doctores del Departamento, en su sesión de fecha de Uno de Diciembre de dos mil diez, tomó el acuerdo de dar el consentimiento para su tramitación a la tesis doctoral titulada "**Estimación de la Potencia Eólica en una zona mediante el apoyo de estaciones meteorológicas de referencia y el empleo de técnicas estadísticas no paramétricas, funcionales y de *Machine Learning*. Aplicación a las islas Canarias**", presentada por el doctorando D. SERGIO VELÁZQUEZ MEDINA y dirigida por los Doctores D. JOSE ANTONIO CARTA GONZÁLEZ y D. JOSÉ MARÍA MATIAS FERNÁNDEZ.

Y para que así conste, y a efectos de lo previsto en el Artº 73.2 del reglamento de Estudios de Doctorado de esta Universidad, firmo la presente en Las Palmas de Gran Canaria, a 01 de Diciembre de dos mil diez.

Fdo.: José Manuel Santana Quintana

UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
Programa de Doctorado Tecnología Industrial
(Bienio 1998-2000)

TESIS DOCTORAL

ESTIMACIÓN DE LA POTENCIA EÓLICA EN UNA ZONA MEDIANTE EL APOYO DE ESTACIONES METEOROLÓGICAS DE REFERENCIA Y EL EMPLEO DE TÉCNICAS ESTADÍSTICAS NO PARAMÉTRICAS, FUNCIONALES Y DE MACHINE LEARNING. APLICACIÓN A LAS ISLAS CANARIAS

Memoria presentada, en cumplimiento de los requisitos
para optar al grado de DOCTOR, por el Ingeniero
Industrial D. Sergio Velázquez Medina

Directores: Dr. D. José Antonio Carta González
Dr. D. José María Matías Fernández

Los Directores El Doctorando

Las Palmas de Gran Canaria, Diciembre de 2010.

Dedicatoria

A mi hijo Héctor,

te compensaré todo el tiempo que te he robado por el desarrollo de este trabajo.

A mi mujer Ana,

mi apoyo en éste y todos mis proyectos en la vida.

A mis padres,

han luchado siempre para darme lo mejor y para que consiguiera mis objetivos personales y profesionales.

A mi hermano,

al que siempre he estado muy unido

AGRADECIMIENTOS

Deseo expresar mi agradecimiento a todas aquellas personas que de alguna forma han contribuido a la realización de esta tesis:

- Al Dr. D José Antonio Carta González (Director de la Tesis). Profesor de la Universidad de Las Palmas de Gran Canaria (ULPGC).
  Muchas Gracias José Antonio por tus continuos actos de motivación hacia mi persona y preocupación por este trabajo, más allá de tu propia responsabilidad como Director del mismo.
- Al Dr D. José Mª Matías Fernández (Director de la Tesis). Profesor de la Universidad de Vigo.

La aportación de su conocimiento y experiencia en la aplicación de las técnicas de Machine Learning ha sido fundamental en el desarrollo de esta tesis.

- Al profesor D. Roque Calero Pérez, Catedrático de la Universidad de Las Palmas de Gran Canaria, quién confió en mí y ha sido de los primeros referentes en mi carrera profesional.
- Al Departamento de Ingeniería Electrónica y Automática y al Departamento de Ingeniería Mecánica de la ULPGC por la aportación de sus recursos para el desarrollo de esta tesis.
- A mis suegros
- A mi cuñado
- A mis compañeros del Área de Ingeniería de Sistemas y Automática de la ULPGC

- Al Instituto Tecnológico de Canarias, S.A. (ITC)
- A Gonzalo Piernavieja Izquierdo, Javier Pardilla Fariña, Salvador Suárez García, Lidia Ramos, Daniel Henríquez, Carlos Hernández, Izzat Sabbagh, Rafael Nebot, Mª Jesús Domínguez, por facilitar toda aquella información que estuviera a su alcance para el desarrollo de la presente tesis, y al resto de compañeros del ITC con los que he desarrollado gran parte de mi carrera profesional.
- Parque Eólico Gaviota, S.A. (PEGASA)
- Agustín Padilla (AMMETRONIC, S.A.).

INDICE GENERAL DE LA TESIS

INDICE DE FIGURAS IX
INDICE DE TABLAS XIX

1. INTRODUCCION 1
1.1. Objetivos de la tesis. 6
1.2. Metodología de la tesis. 7
1.3. Estructura de la tesis. 8

2. PROCESO DE LA EVALUACIÓN ENERGÉTICA DEL VIENTO. 9
2.1 Introducción. 9
2.2 Origen y características generales del viento. 9
2.3 Medición del viento. 11
2.3.1 Ubicación de los anemómetros. 13
2.3.2 Dispositivos de registro y almacenamiento. 14
2.3.3 Frecuencias de las medidas. 17
2.3.4 Campaña de medidas. 17
2.3.5 Unidades de medida del viento. 17
2.3.6 Elección de instrumentos. 18
2.4 Tratamiento de los datos de viento en el análisis del potencial eólico. 19
2.4.1 Distribuciones temporales. 19
2.4.2 Distribuciones de frecuencia. 21
2.5 Representación matemática de los regímenes de viento. 24
2.5.1 Número efectivo de observaciones. 28
2.6 Pruebas de hipótesis estadísticas. 33
2.7 Pruebas de bondad de ajuste. 34
2.7.1 Prueba de Chi2. 35
2.7.2 Prueba de K-S. 36
2.7.3 Prueba de Anderson-Darling. 38
2.7.4 Prueba de los gráficos de probabilidad. 39

2.8 Valoración de la energía eólica. 39
2.8.1 Energía eólica disponible. 39
2.8.1.1 Histogramas de densidad de energía. 41
2.8.2 Energía eólica máxima recuperable. Límite de Betz 43

3. ESTIMACION DE LA PRODUCCION DE ENERGIA ELECTRICA DE ORIGEN EOLICO. LOS PARQUES EOLICOS 49
3.1 Introducción. 49
3.2 Sistemas de conversión de la energía eólica. Los Aerogeneradores 49
3.2.1 Características de funcionamiento de las turbinas eólicas. 60
3.3 Métodos de estimación de la energía eléctrica de origen eólico. 67
3.3.1 Método estático. 68
3.3.2 Método cuasidinámico. 72
3.3.3 Método dinámico. 73
3.4 Sistemas de explotación de la energía eólica. Los Parques Eólicos 74
3.4.1 Parques eólicos interconectados con la red eléctrica 76
3.4.2 Parques eólicos en sistemas aislados 76
3.4.3 Parques eólicos con consumos asociados 77

4 FUNDAMENTOS DE LAS REDES NEURONALES 79
4.1 Introducción a las redes neuronales 79
4.2 Funcionamiento de una neurona biológica 81
4.3 Características de una red neuronal artificial 86
4.3.1 Notación: 88
4.3.2 Funciones de Transferencia: 89
4.3.2.1 Limitador fuerte (Hardlim): 90
4.3.2.2 Función de transferencia lineal (purelin): 91
4.3.2.3 Función de transferencia sigmoidal (logsig): 92
4.3.3 Topología de una Red: 92
4.4 Principales tipos de redes neuronales 99
4.4.1 Perceptrón 99
4.4.1.1 Antecedentes: 99

4.4.1.2 Estructura de la red: 103
4.4.2 Adaline 104
4.4.2.1 Antecedentes: 104
4.4.2.2 Estructura de la red: 106
4.4.3 Backpropagation 107
4.4.3.1 Anteceentes: 107
4.4.3.2 Estructura de la Red: 110
4.4.3.3 Regla de Aprendizaje 111
4.4.3.3.1 Red Backpropagation con momentum: 122
4.4.3.3.1.1 Red Backpropagation con rata de aprendizaje variable: 125
4.4.3.3.2 Método del Gradiente Conjugado: 127
4.4.3.3.3 Algoritmo de Levenberg - Marquardt: 128

5 SISTEMAS DE INTELIGENCIA ARTIFICIAL BASADOS EN PROBABILIDAD. LAS REDES BAYESIANAS 133
5.1 Introducción 133
5.2 Algunos conceptos básicos de la teoría de probabilidad. 133
5.2.1 Medida de Probabilidad 134
5.2.2 Distribuciones de Probabilidad 135
5.2.3 Teorema de Bayes 139
5.3 Algunos conceptos básicos sobre grafos 141
5.3.1 Introducción 141
5.3.2 Conceptos básicos y definiciones 141
5.4 Redes Bayesianas 142
5.4.1 Aprendizaje de Redes Bayesianas 143
5.4.1.1 Aprendizaje Paramétrico 144
5.4.1.2 Aprendizaje Estructural 147

6. METODOS MEASURE-CORRELATE-PREDICT (MCP) PARA LA ESTIMACION DE DATOS EOLICOS. 153
6.1. Introducción. 153
6.2. Método de Derrick 154

6.3. Método de Niesel et al 155
6.4. Método de García Rojo 156
6.5. Método de Rogers et al (Variance Ratio Method) [9] 157
6.6. El Método Weibull Scale (WSM). 158
6.7. Nuevo Método MCP propuesto en la presente tesis 159

7. EL POTENCIAL EOLICO EN CANARIAS. INFORMACION EOLICA DE PARTIDA UTILIZADA EN LA TESIS 163
7.1. Características generales del viento en Canarias. 163
7.2. Información eólica de partida utilizada en la presente tesis 166
7.2.1 Exposición de los Estadísticos principales de la información eólica disponible 168

8. EVOLUCION DEL APROVECHAMIENTO DE LA ENERGIA EOLICA EN CANARIAS. SITUACION ACTUAL Y PERSPECTIVAS FUTURAS 179
8.1. Introducción 179
8.2. Evolución de la contribución de la Energía Eólica al sector de la energía léctrica en Canarias. 179
8.3. Objetivos estratégicos establecidos para el aprovechamiento de la energía eólica en Canarias. 184
8.4. La ordenación del territorio canario como factor determinante en la planificación energética 186
8.5. Conclusiones 190

9 INFLUENCIA DE LAS SEÑALES DE LA CAPA DE ENTRADA DE LAS REDES NEURONALES EN LA ESTIMACIÓN DE LA POTENCIA EÓLICA DE UN SITIO CANDIDATO 193
9.1 Introducción 193
9.2 Arquitectura de las Redes Neuronales utilizadas. 196
9.3 Datos utilizados en el estudio 197
9.4 Metodología 201
9.5 Análisis de los resultados 205
9.5.1 Conclusiones al capítulo 216

10 UTILIZACIÓN DE LAS REDES BAYESIANAS EN LA ESTIMACIÓN DE LA POTENCIA GENERADA POR UNA TURBINA EÓLICA EN UN EMPLAZAMIENTO CANDIDATO..... 219
10.1 Introducción..... 219
10.2 MCP métodos usados para comparación 221
10.2.1 Método de Derrick 222
10.2.2 .Método de Nielsen y Otros..... 223
10.3 Método Propuesto 224
10.3.1 Las Redes Bayesianas..... 224
10.3.2 El proceso de aprendizaje en las Redes Bayesianas 225
10.3.3 Clasificadores en las Redes Bayesianas 226
10.4 Datos Meteorológicos utilizados..... 227
10.5 Metodología..... 232
10.5.1 Metodología para aprender y evaluar los modelos 232
10.5.2 Metodología del análisis..... 234
10.6 Parámetros estimados por el método de los bins 235
10.7 Métricas de evaluación utilizadas..... 236
10.8 Resultados del Análisis 237
10.9 Conclusiones..... 245

11 UN NUEVO MÉTODO PROBABILÍSTICO PARA LA ESTIMACIÓN DE LAS CARACTERÍSTICAS DE LA VELOCIDAD DEL VIENTO A LARGO PLAZO EN UN SITIO CANDIDATO. 247
11.1 Introducción..... 247
11.2 Métodos utilizados en la comparación 248
11.2.1 Joint Probabilistic Approach (JPA) 248
11.2.2 El Weibull Scale Method (WSM). 249
11.2.3 El Variance Ratio Method (VRM) 250
11.3 Método propuesto 251
11.3.1 Estimación de la Distribución Marginal utilizada. 253
11.4 Datos meteorológicos utilizados..... 254
11.5 Metodología..... 258
11.6 Características del viento analizadas..... 260
11.6.1 Velocidad del viento 260

11.6.2 Densidad de la potencia eólica 261
11.6.3 Potencia Eléctrica 261
11.7 Métricas utilizadas en la evaluación 263
11.8 Análisis de los resultados 263
11.9 Conclusiones 277

12 COMPARACIÓN ENTRE LAS REDES NEURONALES ARTIFICIALES Y LOS ALGORITMOS MCP LINEALES EN LA ESTIMACIÓN A LARGO PLAZO DEL COSTE DEL KWh PRODUCIDO POR UN AEROGENERADOR EN UN EMPLAZAMIENTO CANDIDATO. 279
12.1 Introducción 279
12.2 Métodos MCP utilizados para la comparación 281
12.3 Arquitectura de las Redes Neuronales Artificiales utilizadas 282
12.4 Datos meteorológicos y de los aerogeneradores utilizados. 283
12.5 Metodología 288
12.5.1 Escenario A 290
12.5.2 Escenario B 291
12.6 Parámetros analizados 292
12.6.1 Velocidad del viento 292
12.6.2 Densidad de la potencia eólica 292
12.6.3 Potencia eléctrica 293
12.6.4 Coste de la energía eléctrica 293
12.7 Métricas utilizadas en la evaluación numérica de los resultados. 294
12.8 Análisis de los resultados 295
12.9 Conclusiones 306

13 CONCLUSIONES DE LA TESIS Y LINEAS DE INVESTIGACION FUTURAS QUE SE PROPONEN 309
13.1 Introducción 309
13.2 Aportaciones de la tesis 310
13.3 Conclusiones 313
13.4 Líneas de investigación futuras que se proponen 316

REFERENCIAS BIBLIOGRAFICAS 317

ANEXO: Artículos publicados derivados del trabajo de investigación realizado en la tesis

Artículo 1:

Título: “Influence of the level of fit of a density probability function to wind-speed data on the WECS mean power output estimation”

Revista: Energy Conversion and Management, 2008;49. pp 2647-2655

Artículo 2:

Título: “A review of wind speed probability distributions used in wind energy analysis. Case studies in the Canary Islands”.

Revista: Renewable and Sustainable Energy Reviews, 2009;13. pp 933-955

Articulo 3:

Título: “Use of Bayesian networks classifiers for long-term mean wind turbine energy output estimation at a potential wind energy conversion site”

Revista: Energy Conversion and Management, 2011; 52. pp 1137–1149

INDICE DE FIGURAS

Figura 2.1: Mapa de los cinturones de vientos alisios y de las zonas de calmas ecuatoriales.. 11
Figura 2.2: Anemómetro de cazoletas y veleta 12
Figura 2.3: Torre anemométrica 14
Figura 2.4: Dispositivo de registro y almacenamiento 16
Figura 2.5: Dispositivo lector de tarjetas RAM de almacenamiento 16
Figura 2.6: . Velocidad media mensual y anual del viento. Estación GC0110. Año 2008 20
Figura 2.7: . Coeficiente de variación mensual de la velocidad del viento. Estación GC0110..... 20
Figura 2.8: . Velocidades Medias Horarias por mes. Estación GC0110. Año 2008 21
Figura 2.9: Distribución de frecuencia de velocidades. GC0110. Año 2008 22
Figura 2.10: Distribución de Frecuencias acumuladas de velocidades. GC0110. Año 2008..... 23
Figura 2.11: Distribución de Frecuencia de Direcciones (Rosa de lo vientos). GC0110. 24
Figura 2.12: Densidad de probabilidad experimental y teórica. Estación GC0110. Año 2008... 25
Figura 2.13: Distribución acumulada experimental y teórica. Estación GC0110. Año 2008 26
Figura 2.14: Función de autocorrelación. 28
Figura 2.15: Dependencia de la potencia del viento de la velocidad del mismo 40
Figura 2.16: Distribución de la densidad de energía aprovechable según la dirección del viento. Estación GC0110. Año 2008 42
Figura 2.17: Distribución de la densidad de Energía Aprovechable según la velocidad del viento. Estación GC0110. Año 2008 43
Figura 2.18: Flujo idealizado a través de una turbina eólica representada por un disco (rotor) no giratorio 44
Figura 2.19: Coeficiente de potencia en función de la relación de velocidades después y antes del rotor 47
Figura 2.20: Densidad teórica de energía eólica y porcentaje de energía extraíble con una turbina eólica ideal 48

Figura 3.1: Aerogenerador de Eje Vertical 50
Figura 3.2: Aerogenerador de eje horizontal 51
Figura 3.3: Transferencia de potencia en un convertidor de energía eólica 52
Figura 3.4: Coeficiente de potencia de un rotor de una turbina eólica 61
Figura 3.5: Potencia del rotor de una turbina en función de la velocidad de giro 62
Figura 3.6: Rotor acoplado a un generador de velocidad constante conectado a la red eléctrica 63
Figura 3.7: Rotor acoplado a un generador síncrono de velocidad variable con convertidores AC/DC/AC 64
Figura 3.8: Obtención de la curva potencia-velocidad de una turbina eólica 65
Figura 3.9: Curva de potencia experimental de un aerogenerador 66
Figura 3.10: Curvas de potencia normalizadas de aerogeneradores comerciales 67
Figura 3.11: Acoplamiento curva de potencia-distribución de densidad de probabilidad 68
Figura 3.12: Diagrama de bloques del procedimiento que se utiliza con este método 71
Figura 3.13: Estimación de la variación temporal de la potencia generada 73
Figura 3.14: Esquema de Parque Eólico interconectado con la red eléctrica 76
Figura 3.15: Esquema de Parque Eólico en Sistema Aislado 77
Figura 3.16: Esquema de Parque Eólico con Consumo Asociado 78

Figura 4.1: Neuronas Biológicas 81
Figura 4.2: Cambios asociativos de las fuerzas sinápticas durante el aprendizaje 82
Figura 4.3: Comunicación entre neuronas 84
Figura 4.4: Proceso químico de una sinápsis 85
Figura 4.5: Neurona Artificial 86
Figura 4.6: De la neurona biológica a la neurona artificial 87
Figura 4.7: Proceso de una red neuronal 88
Figura 4.8: Neurona de una sola entrada 89
Figura 4.9: Función de transferencia Hardlim 90
Figura 4.10: Función de transferencia Hardlims 91
Figura 4.11: Función de transferencia lineal 91
Figura 4.12: Función de transferencia sigmoidal 92
Figura 4.13: Neurona con múltiples entradas 93

Figura 4.14: Neurona con múltiples entradas, notación abreviada 94
Figura 4.15: Capa de S neuronas 95
Figura 4.16: Capa de S neuronas con notación abreviada 95
Figura 4.17: Red de tres capas 96
Figura 4.18: Red de tres capas con notación abreviada 97
Figura 4.19: Redes Recurrentes 97
Figura 4.20: Bloque de retardo 98
Figura 4.21: Bloque integrador 98
Figura 4.22: Clasificación de las Redes Neuronales 99
Figura 4.23: Modelo del Fotoperceptrón de Rosenblatt 100
Figura 4.24: Esquema de conexiones de un Perceptrón sencillo 101
Figura 4.25: Perceptrón según Minsky y Papera 102
Figura 4.26: Perceptrón 103
Figura 4.27: Estructura de una red Adaline 106
Figura 4.28: Adaline de una neurona y dos entradas 106
Figura 4.29: Característica de decisión de una red tipo Adaline 107
Figura 4.30: Red de tres capas 110
Figura 4.31: Notación compacta de una red de tres capas 111
Figura 4.32: Disposición de una red sencilla de 3 capas 112
Figura 4.33: Superficie típica de error 120
Figura 4.34: Intervalo de la función t 121
Figura 4.35: Red utilizada para aproximar la función 121
Figura 4.36: Comportamiento típico del proceso de convergencia para una red Backpropagation 123
Figura 4.37: Efecto del coeficiente de momentum 123
Figura 4.38: Trayectoria de convergencia con momentum 124
Figura 4.39: Característica de convergencia para una rata de aprendizaje variable 126
Figura 4.40: Trayectoria del Gradiente Conjugado 128
Figura 4.41: Trayectoria del algoritmo Levenberg-Marquardt 132

Figura 7.1: Características generales del viento en Canarias 163
Figura 7.2: Frecuencia de los vientos alisios en verano 164
Figura 7.3: Frecuencia de los vientos alisios en invierno 165

Figura 7.4: Direcciones predominantes de los vientos típicos del Archipiélago 165
Figura 7.5: Algunos casos de emplazamientos con una distribución de frecuencia de Direcciones con predominancia NE-ENE 172
Figura 7.6: Algunos casos de emplazamientos con una distribución de frecuencia de direcciones con predominancia N-NNE 173
Figura 7.7: Algunos casos de emplazamientos con una distribución de frecuencia de direcciones variables 173
Figura 7.8: Error absoluto relativo medio de la velocidad media anual respecto a la velocidad media a largo plazo.....175
Figura 7.9: Error absoluto relativo medio de las velocidades medias horarias anuales respecto de las velocidades medias horarias a largo plazo 177

Figura 8.1: Participación de las diferentes de energía en la generación eléctrica en España..180
Figura 8.2: Estructura de la producción de energía eléctrica en España según su fuente primaria de procedencia. Datos de finales del año 2009. 180
Figura 8.3: Evolución de la estructura de la producción de energía eléctrica en Canarias según su fuente primaria de procedencia.....181
Figura 8.4: Evolución de la potencia eólica instalada en Canarias.....182
Figura 8.5: Horas equivalentes de funcionamiento en el año 2006 de los diferentes parques eólicos instalados en Canarias. Cada punto representa el dato de un parque eólico. 183
Figura 8.6: Evolución de las horas equivalentes medias de funcionamiento de los parques eólicos existentes en el archipiélago canario.....183
Figura 8.7: Mapas Eólicos de las islas de Gran Canaria y Tenerife 188
Figura 8.8: Ubicación relativa de los parques eólicos instalados en las islas de Gran Canaria y Tenerife. 188

Figura 9.1: Fases del procesos de estimación de las velocidades de viento a largo plazo.....195
Figura 9.2: Ubicación de las estaciones anemométricas utilizadas.....197
Figura 9.3: Rosas de los vientos de estaciones anemométricas en el año 2006: a) WS-5, b) WS-12. 200
Figura 9.4: Curvas características potencia-velocidad del viento de los aerogeneradores utilizados en el estudio.....201

Figura 9.5: Esquema de una ANN con N señales de entrada de velocidad del viento de estaciones de referencia y una señal de salida de velocidad del viento de la estación candidata. 200
Figura 9.6: Esquema de una ANN con 2N señales de entrada de velocidad y dirección angular del viento del viento de N estaciones de referencia y una señal de salida de velocidad del viento de la estación candidata. 201
Figura 9.7: a) Esquema de una ANN con 2N señales de entrada de las componentes cartesianas de velocidad del viento de N estaciones de referencia y dos señales de salida de las componentes cartesianas de velocidad del viento de la estación candidata. b) Descomposición cartesiana de la velocidad del viento 204
Figura 9.8: Métricas CC de los casos A) y B) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo. 206
Figura 9.9: Métricas MARE de los casos A) y B) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo. 206
Figura 9.10: Métricas CC de los casos B) y C) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo. 208
Figura 9.11: Métricas MARE de los casos B) y C) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo. 208
Figura 9.12: Comparación de la métrica CC de dos modelos del caso A) con la correspondiente métrica de varios modelos del caso D) con N=2. Los modelos D) se han generado añadiendo a los modelos del caso A) una segunda estación de referencia la cual posee un R con la estación candidata que es inferior al que posee la primera. 209
Figura 9.13: Comparación de la métrica MARE de dos modelos del caso A) con la correspondiente métrica de varios modelos del caso D) con N=2. Los modelos D) se han generado añadiendo a los modelos del caso A) una segunda estación de referencia la cual posee un R con la estación candidata que es inferior al que posee la primera. 210
Figura 9.14: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso A), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo. 212

Figura 9.15: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso D) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo. 213
Figura 9.16: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso D y caso E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso A), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo. 214
Figura 9.17: Porcentaje del cociente entre el MARE mínimo obtenido al analizar las densidades de potencia media del viento en los casos D) y E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), en función de la estación objetivo considerada. 215
Figura 9.18: Porcentaje del cociente entre el MARE mínimo obtenido al analizar las potencias eléctricas medias generadas por los aerogeneradores en los casos D) y E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), en función de la estación objetivo considerada. 216

Figura 10.1: Situación geográfica de las cuatro estaciones anemométricas utilizadas. 228
Figura 10.2: Evolución interanual de las velocidades medias anuales de la velocidad del viento en las cuatro estaciones utilizadas. 229
Figura 10.3: Histogramas de frecuencias relativas de la velocidad del viento en las cuatro estaciones utilizadas. La columna de la izquierda representa los histogramas del año 2008. La columna de la derecha representa los histogramas construidos con las velocidades del viento del periodo 1999- 230
Figura 10.4: Rosas de los vientos de las cuatro estaciones utilizadas. La columna de la izquierda representa las rosas del año 2008. La columna de la derecha representa las rosas construidas con los datos de viento del periodo 1999-2008. 231
Figura 10.5: Esquema representativo de la metodología utilizada para aprender y evaluar los modelos 233
Figura 10.6: Errores obtenidos con los distintos modelos de la estación WS-1 en la etapa primera del proceso metodológico utilizado 238
Figura 10.7: Errores obtenidos con los distintos modelos de la estación WS-2 en la etapa primera del proceso metodológico utilizado 238

Figura 10.8: Errores obtenidos con los distintos modelos de la estación WS-3 en la etapa primera del proceso metodológico utilizado 239
Figura 10.9: Errores obtenidos con los distintos modelos de la estación WS-4 en la etapa primera del proceso metodológico utilizado 239
Figura 10.10: Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-1. 241
Figura 10.11: Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-2. 241
Figura 10.12: Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-3. 242
Figura 10.13: Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-4. 242
Figura 10.14: Métrica RMSE de los errores cometidos en la estimación de los histogramas de frecuencia de la velocidad del viento a largo plazo de las cuatro estaciones, en función de la métrica RMSE de los errores obtenidos en la primera etapa de evaluación de los modelos. 243

Figura 11.1: Ubicación de la estaciones meteorológicas utilizadas 255
Figura 11.2: Histogramas de las frecuencias relativas de la velocidad del viento del año 2008 para las seis estaciones utilizadas. Cada histograma muestra además el ajuste mediante la Weibull Mixta-pdf y Weibull-pdf. 256
Figura 11.3: Esquema de la metodología utilizada para aprender y evaluar con el modelo propuesto 259
Figura 11.4: Curva de potencia característica del aerogenerador utilizado en el presente estudio. 262
Figura 11.5: Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la velocidad del viento a largo plazo. 265
Figura 11.6: Métrica R2 de los modelos utilizados en la estimación de las distribuciones de la velocidad del viento a largo plazo. 266
Figura 11.7: Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la densidad de potencia eólica a largo plazo. 267
Figura 11.8: Métrica R2 de los modelos utilizados en la estimación de las distribuciones de la densidad de potencia eólica a largo plazo. 267

Figura 11.9: Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la potencia eléctrica generada por un aerogenerador a largo plazo. 268
Figura 11.10: Métrica R2 de los modelos utilizados en la estimación de las distribuciones de la potencia eléctrica generada por un aerogenerador a largo plazo. 269
Figura 11.11: Histogramas de la frecuencia relativa de la velocidad del viento para el periodo 1999-2008 para las seis estaciones utilizadas. Cada histograma muestra además las pdfs estimadas a largo plazo con el método propuesto y que mejor y peor se han ajustado a los datos experimentales. 270
Figura 11.12: Histogramas de la frecuencia relativa de la densidad de la potencia eólica del periodo 1999-2008 para las seis estaciones utilizadas. Cada histograma muestra además, para los mejores ajustes de la figura 11.11, la densidad de potencia eólica estimada a largo plazo con el método propuesto y con el Weibull Scale Method (WSM). 271
Figura 11.13: Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la velocidad del viento durante la etapa de entrenamiento y de estimación a largo plazo. 273
Figura 11.14: Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la densidad de potencia del viento durante la etapa de entrenamiento y de estimación a largo plazo. 273
Figura 11.15: Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la potencia eléctrica durante la etapa de entrenamiento y de estimación a largo plazo. 274
Figura 11.16: Métrica R2 obtenida en la estimación de los histogramas de frecuencia relativa de la velocidad del viento de las seis estaciones en función de la R2 obtenida en la primera fase de la evaluación del modelo. 275
Figura 11.17: RRSE; métrica de los errores obtenidos en la estimación de las distribuciones de la velocidad del viento durante la etapa de entrenamiento, durante la etapa de estimación a largo plazo y cuando se usan las pdfs de la velocidad del viento para el año 2008 como representativas del largo plazo. 276

Figura 12.1: Schematic diagram of an ANN with 2N wind speed and angular wind direction. . 282
Figura 12.2: Location of the weather stations used. 283
Figura 12.3: Velocidades medias interanuales del viento de cada estación meteorológica en el periodo de largo plazo (1999-2008). 284

Figura 12.4: Rosas de los vientos de cada una de las estaciones. La columna de la izquierda representa las rosas de viento del año 2008 y la columna de la derecha representa las rosas de viento construidas con direcciones del viento de todos los años disponibles (1999-2008). 286
Figura 12.5: Power-wind speed characteristic curves of the wind turbines used in the study. 288
Figura 12.6: Stages of the process of estimation of the long-term wind speeds. 289
Figura 12.7: MAPEs obtenidos al estimar las velocidades medias horarias del viento a largo plazo en los quince casos analizados. 296
Figura 12.8: Coeficientes de correlación obtenidos al estimar las velocidades medias horarias del viento a largo plazo en los quince casos analizados..... 297
Figura 12.9: Diferencias entre los MAPEs generados por las ANNs del escenario A y los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo..... 298
Figura 12.10: Diferencias entre los MAPEs generados por las ANNs del escenario B y los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo..... 299
Figura 12.11: MAPEs obtenidos al estimar las densidades de potencia medias horarias del viento a largo plazo en los quince casos analizados. 300
Figura 12.12: MAPEs medios obtenidos al estimar las potencias eléctricas medias horarias generadas por las turbinas eólicas consideradas en este capítulo. 301
Figura 12.13: Factores de capacidad anuales de los aerogeneradores en las estaciones candidatas. 302
Figura 12.14: MAPEs medios obtenidos al estimar los costes específicos de la energía eléctrica generados por los costes de inversión y puesta en marcha (cI) de las turbinas eólicas consideradas. 303
Figura 12.15: MAPEs obtenidos entre las velocidades medias horarias del viento estimadas y observadas a largo plazo en función de los MAPEs generados en la etapa de ensayo de los modelos. 305
Figura 12.16: Coeficientes de correlación obtenidos entre las velocidades medias horarias del viento estimadas y observadas a largo plazo en función de los coeficientes de correlación generados en la etapa de ensayo de los modelos. 306

INDICE DE TABLAS

Tabla 2.1: Cuadro de decisiones..... 34

Tabla 7.1: Datos generales de las estaciones meteorológicas 167
Tabla 7.2: Años disponibles para cada estación meteorológica 168
Tabla 7.3: Velocidades medias anuales en las estaciones meteorológicas 170
Tabla 7.4: Estaciones seleccionada para el cálculo de las métricas observadas de velocidad a largo plazo..... 174

Tabla 8.1: Área de Sensibilidad Eólica afectada para las islas de Gran Canaria y Tenerife por la potencia eólica instalada en el año 2015. 190

Tabla 9.1 : Estaciones meteorológicas utilizadas en el estudio. 198
Tabla 9.2 :Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2002..... 199
Tabla 9.3 :Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2006..... 200

Tabla 10.1 Coeficientes de correlación lineal entre las velocidades de viento de las distintas estaciones anemométricas..... 232
Tabla 10.2 :Modelos que han proporcionado mejor comportamiento en la primera etapa del proceso metodológico seguido..... 240
Tabla 10.3 :Resumen de las métricas utilizadas para valorar de grado de predicción de la densidad de potencia media y la potencia eléctrica media extraíble del viento a largo plazo por las turbinas eólicas seleccionadas. 244

Tabla 11.1 : Medias, desviación estándar (S.D.), curtosis y asimetría de la velocidad del viento recopilada en los diferentes anemómetros de las estaciones meteorológicas. 257
Tabla 11.2 Coeficientes de correlación lineal entre los datos la velocidad del viento de las diferentes estaciones meteorológicas. 258
Tabla 11.3 :Parámetros de la función de densidad de probabilidad de Weibull Mixta de las diferentes estaciones meteorológicas.....264
Tabla 11.4 : Coeficiente de Asociación de la distribución bivariable para el año 2008.....264
Tabla 11.5 Coeficiente de Asociación de la distribución bivariable para el año 2008.....264

Tabla 12.1 Datos generales de las estaciones meteorológicas (en su traducción al inglés, Weather Stations, WS) utilizadas en el estudio. 284
Tabla 12.2 Coeficientes de correlación lineal entre las velocidades medias horarias de las diferentes estaciones meteorológicas. 285
Tabla 12.3 . Coeficiente de Correlación entre las velocidades medias de la estaciones candidatas y las direcciones medias horarias de la estaciones de referencia. 287
Tabla 12.4 Casos estudiados en los escenarios A y B 290

CAPITULO 1

Introducción

INDICE

1. INTRODUCCION 1
1.1. Objetivos de la tesis. 6
1.2. Metodología de la tesis..... 7
1.3. Estructura de la tesis. 8

1. INTRODUCCION

La Directiva 2009/28/CE del Parlamento Europeo y del Consejo, de 23 de abril de 2009 [1], contempla objetivos obligatorios de energías renovables para la UE y para cada uno de los Estados miembros para el año 2020. Establece un marco común para el fomento de la energía procedente de fuentes renovables. Como objetivo general se establece que la cuota de energía procedente de fuentes renovables en el consumo final bruto para el año 2020 y en el global de los países miembro de la UE sea del 20%.

Para conseguir dicho objetivo global, la Directiva marca para cada país miembro una cuota específica de contribución de energías renovables. Para el caso particular de España dicha cuota coincide con el 20% establecido para toda la Unión Europea. Por otro lado se le fija a España una cuota de participación del 40% en la producción bruta de energía eléctrica.

La contribución de las energías renovables a la energía final en España a finales del año 2007 era del 6,9%. (Información Estadística de la CNE, Marzo 2010, [2])

En los primeros estudios realizado por el Ministerio de Industria, Turismo y Comercio en pos de conseguir dichos objetivos generales, se establece como objetivo estratégico para el año 2020 tener una contribución de la EERR a la energía final bruta del 22,7% y del 42,3% a la generación bruta de energía eléctrica. (Informe Secretaría de Estado de la Energía, 2010, [2])

En la Planificación estratégica que se marque para la consecución de dichos objetivos y tal como ocurre en la actualidad, los parques eólicos jugarán un papel fundamental.

En el caso particular de Canarias y según datos publicados por la Comisión Nacional de la Energía [2], **la contribución de las energías renovables a la producción de energía eléctrica bruta en Canarias era, a finales del año 2009, del 7,2%.** De ésta el 4,8% era aportado por los parques eólicos. Este dato se encuentra muy alejado de la contribución del 40% asignada a España por la UE para el año 2020.

Dentro de la estrategia del Gobierno de Canarias por aumentar la contribución de las energías renovables, en general y de la eólica en particular, a la demanda de la energía eléctrica se establece, dentro del marco del Plan Energético de Canarias 2006-2015 (PECAN 2006-2015) y concretamente en el punto 3.2.3 del mismo, como uno de los objetivos relativos con el fomento de las energía renovables el tener instalados **1.025MW de potencia eólica en el año 2015**.

Por lo tanto el objetivo que para la energía eólica se ha marcado el Gobierno de Canarias, mirado desde la perspectiva de los escasos 148 MW instalados a finales del 2009 [2], hará que el sector de la energía eólica, como fuente de energía renovable para la generación de energía eléctrica, tenga un marcado interés en la próxima década. Se generarán oportunidades de

negocio no sólo a los propios promotores de los parques eólicos sino a otros sectores como instaladoras, constructoras, sector del transporte, ingenieros, etc

El fuerte incremento en la instalación de parques eólicos en Canarias a principios de los años 90 y el efecto que sobre la calidad del suministro eléctrico posee este tipo de instalaciones de producción variable, desencadenó en que a mitad de los años 90 el Gobierno de Canarias decidiera regular la instalación de este tipo de infraestructuras a través de los concursos de asignación de potencia eólica.

El primer concurso se convocó mediante la Orden de 9 de mayo de 1.996, convocándose el segundo el 25 de noviembre del mismo año. El último concurso publicado data de Mayo de 2007 y fue publicado mediante la orden de 27 de Abril de 2007 en el Boletín Oficial de Canarias nº 89 de 4 de Mayo de 2007. La potencia eólica ofertada por el gobierno de canarias mediante dicho concurso es de 440 MW.

A nivel mundial Canarias es de las regiones con mejores condiciones para el aprovechamiento de la energía eólica. Esto queda perfectamente comprobado al encontrarse en nuestro archipiélago los parques eólicos con mayor rendimiento energético de los instalados en el mundo, de entre los que cabe destacar el parque eólico de Lomo Cabezo en Gran Canaria, Parque Eólico de Montaña la Mina en Lanzarote y el Parque Eólico de Punta de Teno en Tenerife. Éstos poseen un rendimientos medio de 4000 horas equivalentes año.

La variabilidad del fenómeno viento conlleva a que la oferta eléctrica de origen eólico no sea controlable y por lo tanto pueda adaptarse a unas necesidades eléctricas determinadas. Esto hace que, en principio, la potencia eólica deba estar siempre apoyada por otros sistemas de producción de energía más controlables.

Con el objeto de minimizar el mencionado efecto variable que posee el viento y conseguir una mayor contribución de la energía eólica a la demanda energética, el gobierno español ha adoptado una serie de medidas transformadas en exigencias a través de documentos legislativos. Entre otras, cabe destacar:

- La disposición transitoria sexta del RD 661/2007 [3] establece la obligatoriedad de la previsión futura de la potencia eléctrica de los parques eólicos. En este sentido fija los umbrales de error a partir de los cuales se imputarán a éstos los costes de desvíos establecidos por el mercado eléctrico.
- En el artículo 18 en su apartado e) del mismo Real Decreto anterior [3] se establece la obligatoriedad del cumplimiento de lo dispuesto en el procedimiento operativo P.O. 12.3 de requisitos de respuesta de las instalaciones eólicas frente a huecos de tensión [4].

- En el artículo 20 del Decreto 32/2006 [5], se establece la obligación del titular de la instalación eólica a adoptar medidas correctores cuando se incurra, entre otras, en la circunstancia de no alcanzar el nivel de eficiencia energética establecido para la instalación.

La inversión media específica en las instalaciones de parques eólicos es de 1.200.000€/$MW_{instalado}$. La fuente de ingresos de un proyecto de parque eólico es la venta de la energía eléctrica generada por el mismo. Dicho ingreso es proporcional tanto al precio de venta como a la producción de energía eléctrica. El precio de venta viene regulado por el capítulo IV del RD 661/2007 [3]. Mediante el mismo se puede prever el precio en el horizonte temporal de la inversión.

Con respecto a la estimación de la producción de energía eléctrica es fundamental el conocimiento a largo plazo (horizonte temporal del proyecto) del recurso eólico de la zona donde se implante la instalación. La financiación de este tipo de proyectos tiene un origen, en su mayor medida, externo. Es por ello que la correcta acreditación de la fuente de ingresos del proyecto, durante la vida del mismo, sea primordial para la obtención de la financiación externa así como para conseguir la misma con el menor coste posible. Finalmente la ejecución del proyecto dependerá de la toma de decisión que adopte el promotor del mismo y que estará vinculada a los resultados que se obtengan en el estudio Económico-Financiero.

Por todo lo expuesto anteriormente se concluye que es fundamental, en el desarrollo de proyectos de parques eólicos, el conocer perfectamente el recurso eólico de las áreas donde se implante este tipo de instalaciones.

Para obtener una estimación lo más exacta posible de la producción energética media anual durante la vida útil de un aerogenerador a instalar en una zona eólica dada, se requiere, debido a la variabilidad interanual de la velocidad del viento, del conocimiento de la evolución de las velocidades a largo plazo en dicha zona [6]. Es decir, se precisa disponer de la distribución de frecuencia, $f(v)$, representativa de la velocidad del viento a largo plazo o de series de velocidades horarias del viento recogidas durante suficientes años. Según Hiester and Pennell [6], es difícil de estimar con cierta precisión los valores medios del comportamiento del viento con menos de 10 años de datos en el sitio candidato. Esta opción supone incrementar el costo involucrado en la campaña de medida y, fundamentalmente, posponer durante un tiempo, normalmente no aceptable, la toma de decisiones.

Asimismo, cuando los aerogeneradores se instalan configurando parques eólicos, es interesante conocer la rosa de vientos que indique la frecuencia de los vientos ligada a la intensidad de los mismos, ya que la producción energética de un parque eólico es también función de la dirección del viento, debido a la disposición de las turbinas eólicas y por los denominados efectos estelas [7].

Sin embargo, generalmente no se dispone de series de datos de velocidad y dirección del viento de suficientes años en el área de interés. Las campañas de medida que se llevan a cabo con el propósito de investigar el régimen de viento en una potencial área eólica suelen realizarse durante un corto periodo de tiempo. El número de estaciones anemométricas y la duración de estas campañas son siempre un compromiso entre la complejidad del terreno, la extensión del área en estudio, el costo de la campaña, la existencia de datos de viento específicos del sitio y la fecha establecida para la ejecución del proyecto.

Todos los autores coinciden en que como mínimo se precisa de un año de registro de datos con el propósito de analizar las variaciones de la velocidad y dirección del viento a lo largo del mismo. Según Corotis et al [8], con los datos de velocidad del viento de un año es posible tener alrededor del 90% de confiabilidad de que la velocidad media del viento observada esté dentro del 10% de la velocidad a largo plazo. Como se verá en los capítulos siguientes, la potencia del viento varía con el cubo de su velocidad [7], por lo tanto, para el mismo nivel de confianza, el valor correspondiente de la potencia del viento es del 30%.

Para solventar el problema que se plantea cuando se disponen de periodos de registro de datos de viento inferiores a un año y se desee conocer la evolución anual completa, o cuando se dispone de la evolución de la velocidad del viento durante un año concreto y se desea estimar con cierta garantía cual será el comportamiento medio interanual del viento, se han propuesto diversos modelos. Estos modelos intentan extrapolar los datos medidos para estimar los datos desconocidos y eliminar las incertidumbres en la evaluación de la potencia del viento en una localización debido a la variabilidad del clima local.

El más usual de todos los modelos consiste en comparar los datos de la estación candidata (estación de la que se desea estimar los datos) con los correspondientes a los de una estación climatológica de referencia (estación de la que se conocen todos los datos) y corregir las series de datos originales como consecuencia de la comparación.

La mayoría de los modelos propuestos se engloban dentro de los denominados métodos de Medida-Correlación-Predicción (MCP)[9-20], es decir, se basan en la existencia de una buena correlación entre las velocidades del viento del lugar candidato y de la estación de referencia.

Normalmente con estos métodos se suele evaluar la velocidad media del viento a largo plazo en una zona, representada por una estación climatológica, mediante el uso de datos registrados en otra estación climatológica cuando existe un buen coeficiente de correlación entre los datos de viento registrados en ambas.

Uno de dichos métodos es el denominado método de los ratios [20]. Con dicho método la velocidad media estimada a largo plazo en la estación candidata es función de la velocidad media del viento medida en un año dado en dicha estación, de la velocidad media del viento medida en la estación de referencia en el mismo año que la candidata y de la velocidad media a largo plazo en la estación de referencia.

Otro método es el propuesto por Corotis [17]. En este método intervienen, además de las velocidades utilizadas por el método de los ratios, el coeficiente de correlación espacial entre las dos estaciones y las desviaciones estándar de las velocidades del viento en la estación candidata y de referencia. Justus et al. [18] han indicado que estas técnicas de reducción climatológica producen solo una mejora mínima cuando se aplican para evaluar la velocidad media anual del viento, aunque algún avance puede obtenerse en la estimación de las velocidades medias mensuales.

Algunos de los métodos MCP predicen únicamente la velocidad media a largo plazo y no permiten estimar la energía media producida por un aerogenerador mediante el uso de los métodos estadístico o cronológico. Debido a ello existen procedimientos, por lo general también basados en el método MCP, pero que se aplican a la serie de datos y no al valor medio de la velocidad [9,18,19].

Barros y Estevan [19] han propuesto un método para estimar la velocidad del viento anual utilizando solo dos o tres meses de datos de velocidades del viento. Como todos los métodos MCP este método se basa en la presunción que la velocidad del viento tiene algún grado de correlación espacial, pero la diferencia con los demás métodos es que no depende de una sola estación climatológica. Este método usa información de velocidades del viento procedentes de varias estaciones de referencia y es por lo que denominan a su método Multiple Climatic Reduction technique (MCRT). Mediante el uso del método MCRT, Barros y Estevan [19] estiman la velocidad media y la desviación típica anual. En ese sentido, utilizando el método de los momentos, podrán estimar los parámetros de escala y forma de la distribución de Weibull y determinar la potencia media obtenible por un aerogenerador haciendo uso del método estático o estadístico. Sin embargo, el método propuesto por Barros y Estevan presenta problemas para simular largos periodos de velocidades horarias.

García-Rojo [16] aplica la teoría de probabilidad conjunta a la correlación de series temporales de viento y predice la velocidad y dirección del viento a largo plazo en una estación candidata apoyándose en la información disponible en una estación de referencia cercana.

Algunos autores indican que los métodos basados en regresiones lineales son fuente de errores significativos y proponen otros más actuales como los de aprendizaje artificial, entre los que se destacan las Redes Neuronales [21-27] y las Redes Bayesianas [28]

El objetivo final en el proceso de estimación, independientemente del método utilizado, es minimizar el error entre los valores estimados y los medidos o reales y maximizar el coeficiente de correlación entre los datos estimados y medidos.

Cada una de las 7 islas pertenecientes al archipiélago canario dispone de su propia red eléctrica a excepción de 2 de ellas que están interconectadas. Por lo tanto, dichos sistemas eléctricos son pequeños y débiles. En el objetivo estratégico que se ha marcado el gobierno español, en general, y el canario, en particular, de aumentar la contribución de la energía eólica a la demanda de energía eléctrica, para el caso particular de canarias con redes eléctrica débiles, se hace necesario aún más el desarrollo de estudios conducentes a minimizar la incertidumbre en la estimación de la producción de energía eléctrica de los parques eólicos.

1.1. Objetivos de la tesis.

Los objetivos generales que se pretenden alcanzar con esta tesis doctoral son:

a) Desarrollar, utilizando técnicas de Machine Learning, un modelo de predicción de la potencia eólica que permita estimar una serie anual de datos en aquellas estaciones del archipiélago canario en las que se cuenta con registros de longitud inferior a un año. A estas estaciones se le denominará estaciones candidatas. Dicho modelo se apoyará en series completas horarias de velocidad y dirección registradas en otras estaciones del archipiélago que se denominarán estaciones de referencia. Este modelo se podrá aplicar en los casos donde se intenta extender la zona de análisis del potencial eólico utilizando estaciones anemométricas móviles y fijas que operarán durante un año. Las estaciones fijas registrarán la velocidad y dirección del viento durante el año completo y las estaciones móviles se irán desplazando de un punto a otro de la zona que se pretende analizar. Dichas estaciones móviles registrarán las velocidades y direcciones del viento en cada punto durante un cierto periodo, inferior a un año. El modelo desarrollado estimará las velocidades durante los periodos restantes del año en que no

se ha medido en los diversos puntos, con el objeto de completar las series anuales de todos los puntos.

b) Desarrollar, utilizando técnicas de Machine Learning y funcionales, modelos de predicción de la potencia eólica a largo plazo, que permita estimar una serie de varios años en aquellas estaciones del archipiélago canario en las que se cuenta con registros de longitud anual, las cuales denominaremos candidatas. Dichos modelos se apoyarán en series de varios años de velocidades y direcciones horarias registradas en otras estaciones del archipiélago, que llamaremos estaciones de referencia, en las cuales un año de registro coincide con el año disponible en la candidata.

c) Llevar acabo una evaluación comparativa de diversas técnicas que permitan predecir las velocidades del viento a largo plazo en una zona dada del archipiélago canario, partiendo del conocimiento de las velocidades y direcciones de diferentes estaciones de referencia.

1.2. Metodología de la tesis.

Para alcanzar los objetivos trazados se propone un plan de trabajo que se desarrolla en varias fases:

1. Recopilación y análisis de la bibliografía relacionada con el tema objeto de estudio.
2. Recopilación de las series de datos horarios de velocidad y dirección del viento registrado en el archipiélago canario para su posterior análisis y selección de los mismos en función de criterios de fiabilidad y longitud de registro
3. Elección de los programas más adecuados para la implementación de las rutinas de programa que generarán los modelos, atendiendo a criterios de agilidad y flexibilidad..
4. Definición de las variables que almacenarán toda la información eólica disponible
5. Implementación de las rutinas de programa correspondientes para la identificación de los diferentes modelos.
6. Exposición de los resultados e interpretación de los mismos
7. Presentación de Conclusiones y Líneas Futuras de Actuación

1.3. Estructura de la tesis.

El documento de la tesis se encuentra estructurado en 12 capítulos, incluyendo el presente:

En el capítulo 2 se realiza una introducción al proceso de evaluación energética del viento, con el propósito de presentar una serie de conceptos básicos necesarios para el desarrollo de la tesis.

En el capítulo 3 se analizan las características de funcionamiento de las turbinas eólicas y los métodos utilizados para estimar la energía eléctrica producida por un aerogenerador inmerso en un determinado régimen de vientos.

En el Capítulo 4 se analizará la evolución de la aplicación de la energía eólica en Canarias y su contribución a la demanda de energía. Se comparará la situación actual de la energía eólica y las perspectivas futuras existente para la misma.

En los capítulos del 5 al 7 se describirán las diferentes técnicas estadísticas utilizadas en este trabajo en los procesos de estimación del recurso eólico.

En el capítulo 8 se expone la información de partida utilizada en el estudio. En este caso se referirá fundamentalmente a la información eólica.

En los capítulos del 9 al 11 se exponen diferentes trabajos de investigación realizados en el marco de los objetivos establecidos para la presente tesis.

En el capítulo 12 se exponen las conclusiones de la tesis y las líneas futuras de trabajo que se derivan de la misma.

CAPITULO 2

Proceso de la Evaluación Energética del viento.

INDICE

2. PROCESO DE LA EVALUACIÓN ENERGÉTICA DEL VIENTO. 9
2.1 Introducción. 9
2.2 Origen y características generales del viento. 9
2.3 Medición del viento. 11
2.3.1 Ubicación de los anemómetros. 13
2.3.2 Dispositivos de registro y almacenamiento. 14
2.3.3 Frecuencias de las medidas. 17
2.3.4 Campaña de medidas. 17
2.3.5 Unidades de medida del viento. 17
2.3.6 Elección de instrumentos. 18
2.4 Tratamiento de los datos de viento en el análisis del potencial eólico. 19
2.4.1 Distribuciones temporales. 19
2.4.2 Distribuciones de frecuencia. 21
2.5 Representación matemática de los regímenes de viento. 24
2.5.1 Número efectivo de observaciones. 28
2.6 Pruebas de hipótesis estadísticas. 33
2.7 Pruebas de bondad de ajuste. 34
2.7.1 Prueba de Chi2. 35
2.7.2 Prueba de *K-S*. 36
2.7.3 Prueba de Anderson-Darling. 38
2.7.4 Prueba de los gráficos de probabilidad. 39
2.8 Valoración de la energía eólica. 39
2.8.1 Energía eólica disponible. 39
2.8.1.1 Histogramas de densidad de energía. 41
2.8.2 Energía eólica máxima recuperable. Límite de Betz. 43

2. PROCESO DE LA EVALUACIÓN ENERGÉTICA DEL VIENTO.

2.1 Introducción.

En este capítulo se lleva a cabo una introducción a las características generales del viento y al proceso de medida y análisis del potencial energético del mismo, con el propósito de presentar una serie de conceptos básicos necesarios para el desarrollo de la tesis.

2.2 Origen y características generales del viento.

La fuente primordial de la energía inyectada a nuestra atmósfera es el Sol, que continuamente se desprende de parte de su masa irradiando al espacio ondas de energía electromagnética y partículas dotadas de elevada energía. De esta manera, al exterior de la atmósfera llegan unos 1,368[1] W/m^2 [28], cifra denominada “constante solar”; aunque, debido a factores atmosféricos y orográficos, la radiación que llega al suelo es de unos 900 W/m^2 [29], que es transferida nuevamente en varias formas al aire que la circunda.

A escala planetaria, durante el año, debido a la redondez de la Tierra y la inclinación de su eje de rotación respecto al plano de la eclíptica, las regiones tropicales reciben más energía solar y las regiones polares reciben menos. Como resultado de estos diferentes niveles de absorción de la energía solar[2] se originan diferentes niveles de calentamiento que ocasionan gradientes de presión en la atmósfera. El gradiente de presión es la fuerza[3] motivadora que causa que el aire se desplace lejos de las áreas de altas presiones hacia las zonas donde éstas son menores produciendo el viento. Debido a que la Tierra gira alrededor del Sol describiendo una órbita elíptica, uno de cuyos focos es el mismo Sol, la intensidad de la radiación solar es distinta según las estaciones del año, y consecuentemente la velocidad y dirección del viento varían en general a lo largo del año.

A parte de la fuerza del gradiente de presiones originada por el desigual calentamiento de la superficie terrestre, existen tres controles más sobre el movimiento horizontal del aire cerca de la superficie terrestre: las fuerzas de Coriolis, consecuencia de la rotación de la Tierra, que aceleran las partículas de aire en movimiento y modifican las trayectorias de las partículas

[1] Valor aproximado obtenido de mediciones recientes realizadas por los satélites.
[2] A las diferentes absorciones de energía solar de las regiones polares y tropicales es necesario añadir los efectos térmicos que tienen sobre la circulación general atmosférica la presencia de las grandes masas continentales y los océanos [34]
[3] La fuerza del gradiente de presión tiene componentes horizontal y vertical, pero esta última es mucho menor que la componente horizontal [28]

inclinándolas hacia la derecha en el hemisferio Norte, y a la izquierda en el hemisferio Sur; las aceleraciones centrípetas, consecuencia de las curvaturas de las isobaras; y las fuerzas de fricción, debidas a la fricción del aire con la superficie terrestre cuyos efectos hacen disminuir la velocidad del viento exponencialmente cerca de la misma[4] [30].

La compleja dinámica de la circulación atmosférica [30; 31], da lugar a varios tipos de vientos en el planeta. Diversas referencias [31-33], señalan los vientos ecuatoriales del oeste, muy patentes sobre África y sur de Asía[5]; los vientos del oeste de las latitudes medias; los vientos polares del este; y los vientos alisios, importantes a causa de su enorme área de influencia, pues soplan en ambos lados del ecuador alrededor de todo el globo y destacan por su constancia en la dirección (NE en el hemisferio norte y el SE en el hemisferio sur) y velocidad (Figura 2.1)[6].

Además de los vientos macroclimáticos hay que señalar la existencia de vientos de carácter local provenientes de características microclimáticas locales [31; 34], los derivados de efectos térmicos como las brisas marinas y terrestres[7] [31; 34-37] o provocados por características orográficas y topográficas como los efectos de canalización del valle o el cañón, barreras topográficas[8], etc. [6,37-38], que se manifiestan más claramente cuando los generales son débiles, existiendo zonas en las que son de tal importancia que encubren al general o macroclimático.

[4] La modelización de la variación de los vientos con la altura se analiza en el capítulo 6.
[5] En Asía, a estos vientos se les conoce como el “monzón de la India”
[6] Los límites de los alisios están indicados en la figura por líneas continuas (enero) y de trazos (julio). Las Islas Canarias quedan en invierno en el límite de la zona de influencia de estos vientos, mientras en verano quedan de lleno inmersas en ella.
[7] Como las brisas dependen de los fenómenos térmicos, se deduce que también se producen variaciones diarias más o menos cíclicas en la intensidad y en la dirección del viento [33].
[8] Ejemplos de ello son los vientos de sotavento bora y föhn.

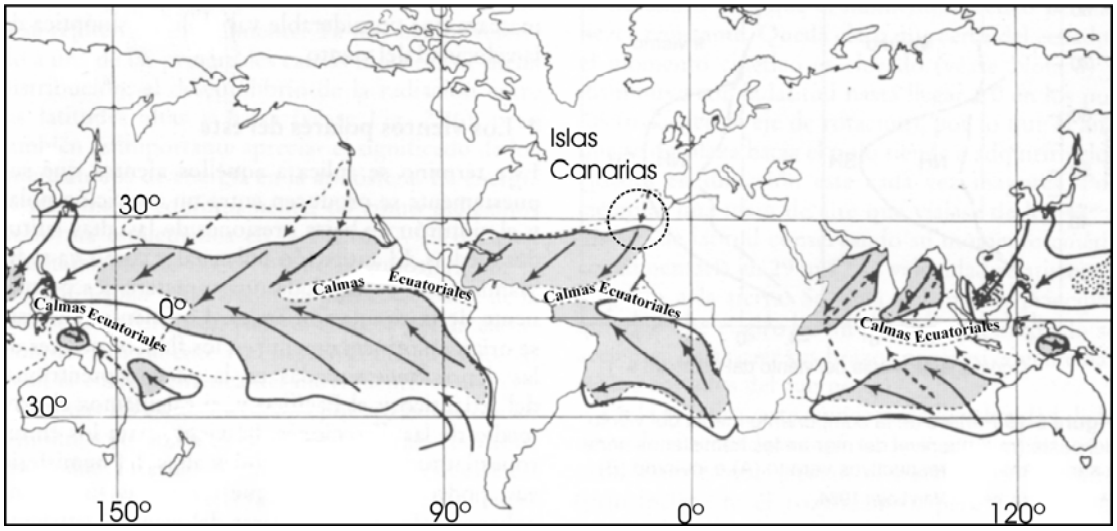

Figura 2.1:Mapa de los cinturones de vientos alisios y de las zonas de calmas ecuatoriales

2.3 Medición del viento.

Como señala Justus (1980) [39], el viento es una magnitud vectorial tridimensional, por tanto, está caracterizada por su módulo, dirección y sentido, que puede ser representada por un vector viento medio al cual se le superponen pequeñas variaciones aleatorias.

Si bien el vector viento medio puede ser representado por sus tres componentes en cualquiera de los sistemas habituales de coordenadas, se suele adoptar frecuentemente la representación en coordenadas cilíndricas. La componente horizontal del viento se representa por un vector de dos dimensiones, cuyo módulo es la velocidad horizontal, y el ángulo es la dirección sobre el plano horizontal. La componente vertical será positiva hacia arriba.

Aunque es posible inferir la velocidad y, algunas veces, la dirección de los vientos por los cambios de las propiedades de la atmósfera [30], con frecuencia se necesita obtener medidas más directas del movimiento atmosférico. Los instrumentos cuyos sensores miden el flujo del aire se llaman anemómetros, los cuales, según Le Gouriérès (1983) [33], se pueden clasificar en tres categorías principales: anemómetros de rotación (anemómetros de cazoletas, anemómetros de hélices, anemómetros de canalones, etc.), anemómetros de presión (anemómetro de Dines, anemómetro de Best Romani, etc.), y otros (anemómetros de hilo caliente, los de efecto sónico, anemómetros láser, anemómetros SODAR de efecto Doppler, anemómetros de ultrasonidos, etc.).

Figura 2.2:Anemómetro de cazoletas y veleta

Entre los anemómetros anteriormente mencionados, los más conocidos y frecuentemente empleados en el análisis de la energía del viento son los de rotación con cazoletas, los cuales normalmente consisten en tres cazoletas de forma troncocónica[9] o semiesférica montadas simétricamente alrededor de un eje vertical (Figura 2.2). Como la fuerza en el lado cóncavo de la cazoleta es mayor que el lado convexo, la rueda de cazoletas gira, siendo la velocidad de rotación proporcional a la velocidad del viento en el plano de giro. La gran ventaja de los anemómetros de cazoletas es que miden las dos componentes horizontales del viento[10], sin embargo al ser su constante de tiempo[11] varía inversamente proporcional a la velocidad del viento, se aceleran más rápidamente que lo que se desaceleran y por lo tanto sobrestiman la velocidad del viento [39; 40]. Otra causa de error, del orden del 6 al 8%, del anemómetro de cazoletas es originada por la componente vertical de la velocidad del viento. Los sensores de

[9] Las de forma de tronco de cono, con ángulo en el vértice de 90º presentan la ventaja de reducir el fenómeno de sobrevelocidad. (Lindley, 1975)

[10] Para las aplicaciones de la energía eólica, se considera que en las inmediaciones del suelo el viento es prácticamente horizontal, pues aunque existen vientos ascendentes o descendentes, su velocidad en sentido vertical es generalmente despreciable en comparación con la horizontal, salvo en casos singulares.

[11] Describe el tiempo que se requiere para que el sensor responda al 63.2% (1-1/e) frente a un cambio en escalón de la señal de entrada.

los anemómetros generan alguna forma de señal[12], que es transmitida a un aparato donde es tratada para facilitar su interpretación y/o almacenamiento. Los anemómetros de rotación se complementan con un dispositivo denominado veleta para captar la dirección de la velocidad del viento. La veleta consiste en un dispositivo montado sobre un eje vertical y de giro libre, de tal modo que puede moverse cuando el viento cambia de dirección y que se acopla a transductores que generan una señal[13] [6].

2.3.1 Ubicación de los anemómetros.

Ya que, como consecuencia del rozamiento con al superficie terrestre, la velocidad del viento varía con la altura, la Organización Meteorológica Mundial (O.M.M.) precisa que el emplazamiento de los sensores de medida del viento en superficie deben situarse a una altura de 10 metros[14]sobre el nivel de suelo en terreno descubierto, con el objeto de que se puedan establecer comparaciones homogéneas [39]. El terreno es definido por la O.M.M. como “una superficie donde la distancia entre el anemómetro y cualquier obstáculo debe ser por lo menos de diez veces la altura del obstáculo”.

[12] Voltaje instantáneo producido por un generador eléctrico conectado al eje de la rueda de cazoletas; señal de salida de un interruptor optoeléctrico; etc.
[13] Generadas por potenciómetros, circuitos de capacidad o inductancia variable, reóstatos de contacto, etc.
[14] En el caso de evaluación del funcionamiento y operación de una determinada turbina eólica, es conveniente realizar las medidas a la altura del buje para evitar las incertidumbres de la variación vertical del viento.

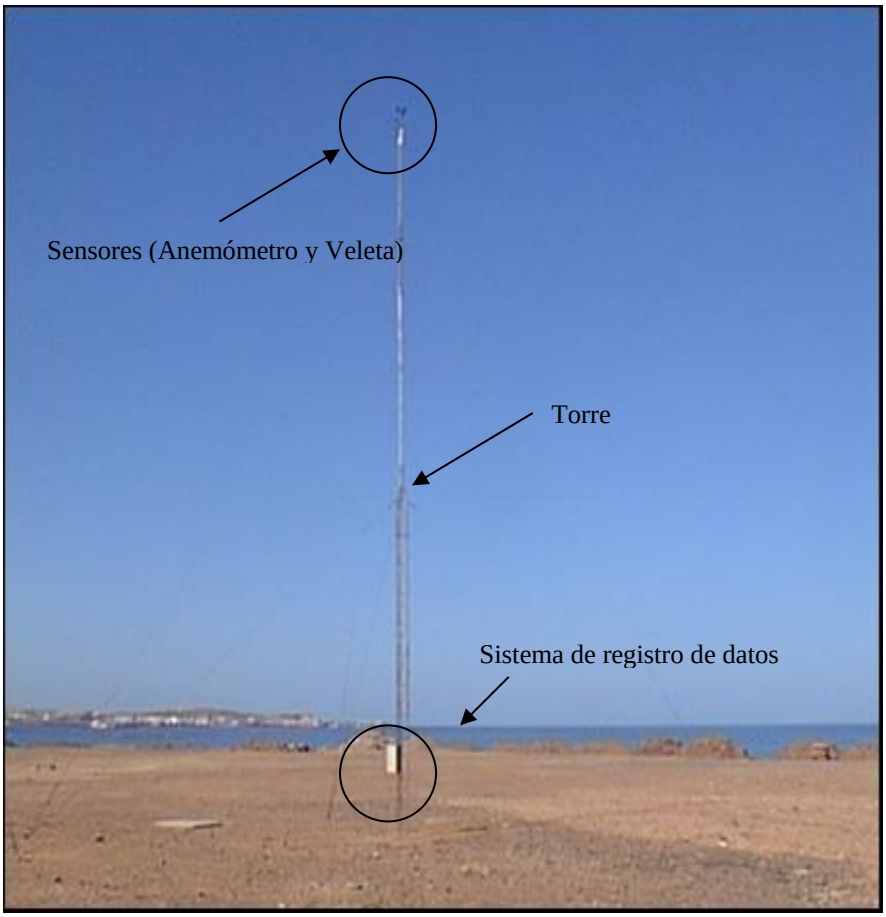

Figura 2.3:Torre anemométrica

Los sensores se suelen situar en torres (Figura 2.3) de tal manera que éstas no influyan en las medidas de aquellos [41-45], bien por presentar un obstáculo a la dirección del viento o por que las vibraciones desarrolladas por dichas torres bajo las cargas de viento causen falsas lecturas de los sensores y aceleren sus desgastes.

2.3.2 Dispositivos de registro y almacenamiento.

Los dispositivos de registro y almacenamiento son clasificados por Hiester y Pennenll (1981) [6] en cuatro clases según su capacidad de almacenamiento y postprocesado de datos.

Los instrumentos de clase I no tienen ninguna capacidad de almacenamiento. Si los datos deben coleccionarse, un observador humano debe leer en un visualizador y anotar la

información. Esto restringe las aplicaciones de los sistemas clase I a dos tipos de usos: a) programas de medida intensiva de corta duración (medidas puntuales con anemómetros manuales en puntos seleccionados de interés) y b) programas de larga duración que requieren que el observador dedique solo una pequeña porción del tiempo a la lectura de datos (Son ejemplos típicos de su uso los aeropuertos, las bases militares, los barcos, los centros meteorológicos, etc.).

Los instrumentos de clase II caracterizan el viento con un único número (por ejemplo la velocidad media del viento en un periodo dado tal como un mes) sacrificando la información utilizada para su cálculo. Por tanto, tienen una utilidad muy limitada desde el punto de vista del análisis energético eólico.

Los sistemas de la clase III procesan los datos y los graban en resúmenes o histogramas. Usan un microprocesador para calcular las estadísticas de interés y almacenan la información en uno de los muchos registros de almacenamiento que disponen. Con los sistemas clase III es posible coleccionar y almacenar mucha información importante para el análisis final y presentación de resultados. Sin embargo, la secuencia de datos se pierde.

Los sistemas de clase IV almacenan datos de series de tiempo en cualquiera de las dos formas, en bruto o procesada. La información procesada puede ser simplemente la media de la velocidad del viento y su dirección para cada intervalo programado de tiempo (ejemplo 10 minutos, 20 minutos, una hora, etc.) o la media, varianza, simetría, máxima velocidad del viento, etc., para cada periodo programado a partir de muestras de 1 segundo, o de 1 minuto. La información bruta puede ser simplemente los valores instantáneos de la velocidad del viento y su dirección.

Ya que los sistemas de la clase IV proporcionan la mayor flexibilidad para el análisis de datos suelen ser, actualmente, los sistemas más empleados en el registro de datos de viento con el fin de evaluar la energía del mismo. Dichos dispositivos (figura 2.4), alimentados frecuentemente por baterías, suelen permitir registrar la información bruta o procesada en una memoria interna (buffer) así como en dispositivos de almacenamiento periféricos, tales como cintas magnéticas, disquetes, chips eprom y memorias RAM[15] de diversas capacidades. Aunque la tecnología actual de estos dispositivos permite que se pueda acceder a la información almacenada en una estación remota mediante el uso de líneas de telefonía, radio, o satélite, los sistemas más frecuentemente empleados para recuperar la información almacenada precisan del desplazamiento de un operario hasta el punto de instalación del aparato. Uno de dichos sistemas requieren el uso de un ordenador portátil, de un interfase

[15] Acrónimo de Random Acces Memory

RS232 y de un programa de comunicaciones que permita establecer las comunicaciones entre el ordenador y la estación a fin de realizar el trasvase de los datos. El otro sistema, probablemente el más frecuentemente empleado, utiliza los dispositivos de almacenamiento periféricos ya mencionados para transportar la información desde la estación hasta el centro de análisis, en donde, por medio de un lector (Figura 2.5), se trasvasa de nuevo a un ordenador, vía RS232, utilizando un programa de comunicación y de conversión de códigos.

Figura 2.4:Dispositivo de registro y almacenamiento

Figura 2.5:Dispositivo lector de tarjetas RAM de almacenamiento

2.3.3 Frecuencias de las medidas.

La frecuencia de la toma de datos y los intervalos de promedio deben estar en consonancia con el tipo de análisis a que se destinen. Con las prestaciones actuales de los equipos de toma de datos, para una evaluación precisa del potencial eólico, es recomendable tomar muestras de valores del viento con una frecuencia de 5 a 10 segundos, y promedios en intervalos de 10 minutos a 1 hora. (40; 46]

Para análisis detallados de funcionamiento de máquinas eólicas (especialmente de gran tamaño), estabilidades de redes eléctricas donde intervienen parques eólicos o estudios específicos de características de viento (ráfagas, turbulencias, etc.), se requieren frecuencias de datos iguales o superiores a 1 Hz e intervalos de promedio del orden de 1 minuto.

2.3.4 Campaña de medidas.

Del mismo modo que la frecuencia de medida, la duración de las medidas depende principalmente de la aplicación de los datos. Si el propósito es determinar la curva de funcionamiento de una aeroturbina, la duración y número de medidas está recogida en recomendaciones prácticas internacionales aceptadas [45]

Una de las más comunes aplicaciones de las medidas de la velocidad del viento es la estimación de la posibilidad de instalación de aeroturbinas en un determinado lugar. Las siguientes dos directrices suelen ser aceptadas: a) Medir durante un periodo lo más largo, práctica y económicamente, posible, b) intentar, si es posible, medir en cada estación del año, dado que los patrones de la velocidad y dirección del viento son relativamente estacionales.

2.3.5 Unidades de medida del viento.

Aunque los organismos meteorológicos todavía registran rutinariamente las velocidades del viento en unidades tales como km/h, nudos, millas por horas (mph), etc., en energía eólica la velocidad del viento se mide en unidades de m/s.

La dirección del viento se mide normalmente en grados, contados a partir del Norte, o en rumbos. El valor indicado en la medida expresa siempre la dirección de donde procede el viento

2.3.6 Elección de instrumentos.

En la selección de la instrumentación más adecuada para la adquisición de datos de viento de cara a su evaluación energética, aunque esencialmente la elección debe depender de cada aplicación, influyen principalmente los siguientes factores:

- Coste y fiabilidad
- Sensibilidad.[16] Las medidas altamente especializados (como en la investigación de las turbulencias en el interior de un parque de aeroturbinas) requieren, obviamente, instrumentos más sensibles que una estación de registro de viento para evaluación de los recursos eólicos. Es necesario prestar atención la calibración de los sensores. Los instrumentos deben ser calibrados periódicamente para garantizar la fiabilidad de los datos.
- Resolución. La resolución se define como la unidad más pequeña de una variable que se puede detectar. Por ejemplo, un sensor puede tener una resolución de ± 0.1 m/s ó ±1 m/s dependiendo del instrumento. El tipo de sistema de almacenamiento puede limitar también la resolución.
- Robustez. Algunos tipos de instrumentos, aunque son altamente sensibles, son al mismo tiempo muy susceptibles de daño o deterioro por la agresividad de los agentes atmosféricos (agua, corrosión, polvo, temperatura, etc.).
- Error. Es la diferencia entre las indicaciones y el verdadero valor de la señal medida.
- Compatibilidad de las especificaciones de sensibilidad y fiabilidad del sistema completo[17].
- Exactitud y precisión. La exactitud y la precisión son dos características del funcionamiento de los instrumentos que son a menudo tratadas ambiguamente. La exactitud de un instrumento se refiere a la diferencia media entre la salida del instrumento y el verdadero valor de la variable medida. La precisión se refiere a la dispersión

[16] Es la relación entre la salida a fondo de escala y el valor de entrada a fondo de escala, por ejemplo 10 pulsos por m/s.

[17] Probabilidad de que el instrumento continúe funcionando dentro de unos límites de error para un tiempo especificado bajo condiciones específicas. El mejor indicador de la fiabilidad es el funcionamiento pasado de instrumentos similares. En general, los instrumentos simples y robustos con pocas partes son más fiables que los que contienen gran número de partes.

alrededor del valor medio.[18] En general, en los sistemas de media del viento la precisión es bastante alta, siendo la exactitud la preocupación principal.

- Repetibilidad. La repetibilidad de un instrumento es la cercanía de coincidencia entre un número de medidas consecutivas de salida para el mismo valor de entrada, a condición de que las medidas sean hechas bajo las mismas condiciones.
- Reproducibilidad. La cercanía de coincidencia entre medidas de la misma cantidad donde las medidas individuales se han realizado bajo diferentes condiciones definen la reproducibilidad de la medida.
- Autonomía de registro.
- Autonomía de su fuente de alimentación.

2.4 Tratamiento de los datos de viento en el análisis del potencial eólico.

Una vez realizada la campaña de medidas y con el propósito de evaluar el potencial eólico del emplazamiento en cuestión, la siguiente fase es el tratamiento estadístico de los datos recopilados. La finalidad de la misma es representar gráficamente el comportamiento del viento en dicho emplazamiento a través de sus dos parámetros fundamentales medidos, la velocidad y la dirección [36]. En los puntos sucesivos se exponen algunos de los resultados más comunes que se suelen representar en esta fase del estudio del potencial eólico.

2.4.1 Distribuciones temporales.

- Velocidades Medias Mensuales a lo largo de un año. En la figura 2.6 se muestran las fluctuaciones de la velocidad del viento en los diferentes meses del año en relación con la velocidad media anual. Además se han representados las desviaciones típicas mensuales. Resultados éstos obtenidos a partir de las medias horarias de la velocidad.

[18] Por ejemplo, un instrumento puede producir el mismo valor de la medida siempre, pero que el valor puede estar 50% alejado. Por consiguiente, este instrumento tienen alta precisión, pero baja exactitud. Otro instrumento midiendo una variable puede producir medidas sin error medio, pero la dispersión de una medida simple puede variar ampliamente alrededor de la media. Este instrumento tiene alta exactitud, pero baja precisión.

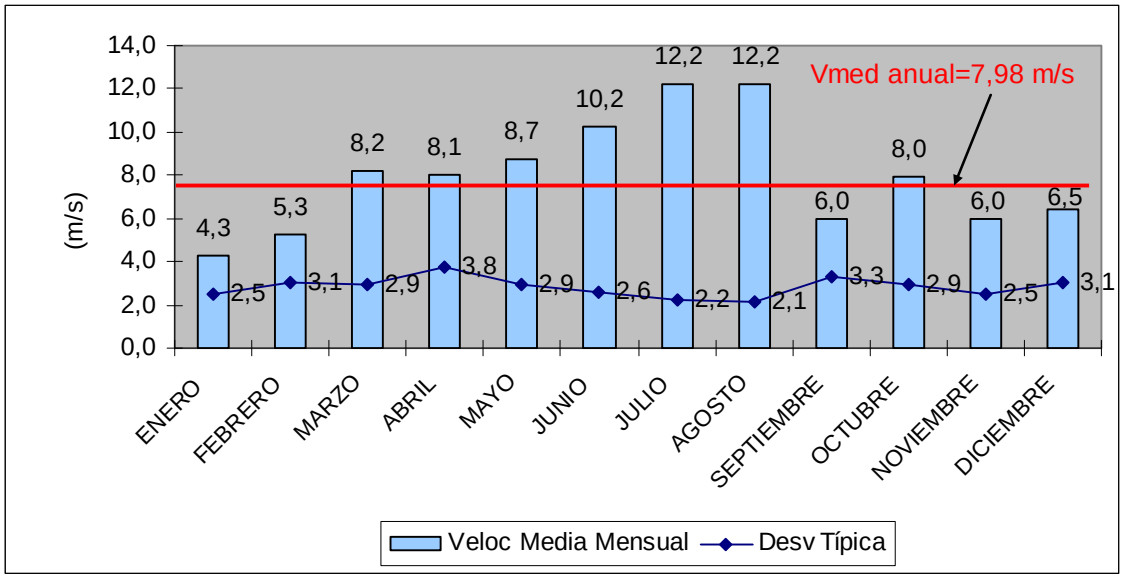

Figura 2.6:. Velocidad media mensual y anual del viento. Estación GC0110[19]. Año 2008

- <u>Coeficiente de variación mensual de la velocidad del viento.</u> Este parámetro refleja el grado de variación del la velocidad del viento para cada mes del año. Se ha representado como el cociente entre la Desviación Típica mensual y la velocidad media mensual. Los resultados se expresan en la Figura 2.7

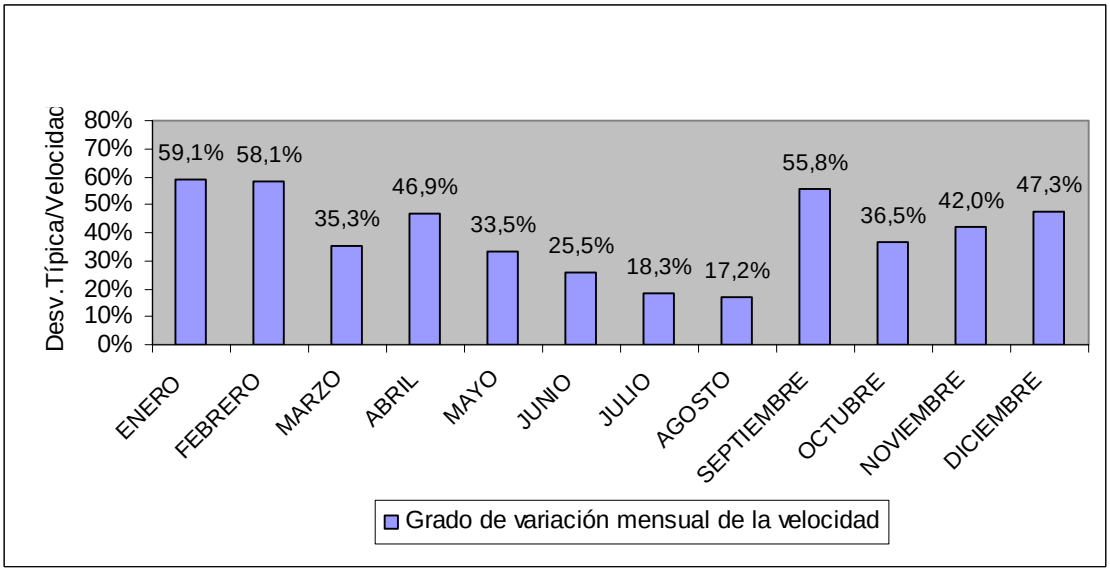

Figura 2.7:. Coeficiente de variación mensual de la velocidad del viento. Estación GC0110. Año 2008

- Velocidades medias horarias en un mes. Representa la variación tipo del viento durante el día. Se han diferenciado para cuatro meses distintos que representan a cada una de las estaciones del año (Figura 2.8). Se observa que el comportamiento de la velocidad del viento durante el día pasa de casi una insensibilidad al tiempo en el mes de Enero (representa a la estación de invierno) a una variación pronunciada entre las 11:00 y las 18:00 en el mes de Agosto (representativo del verano). Entre estos están los comportamientos en los meses de Abril y Octubre representativos de la Primavera y Otoño, respectivamente.

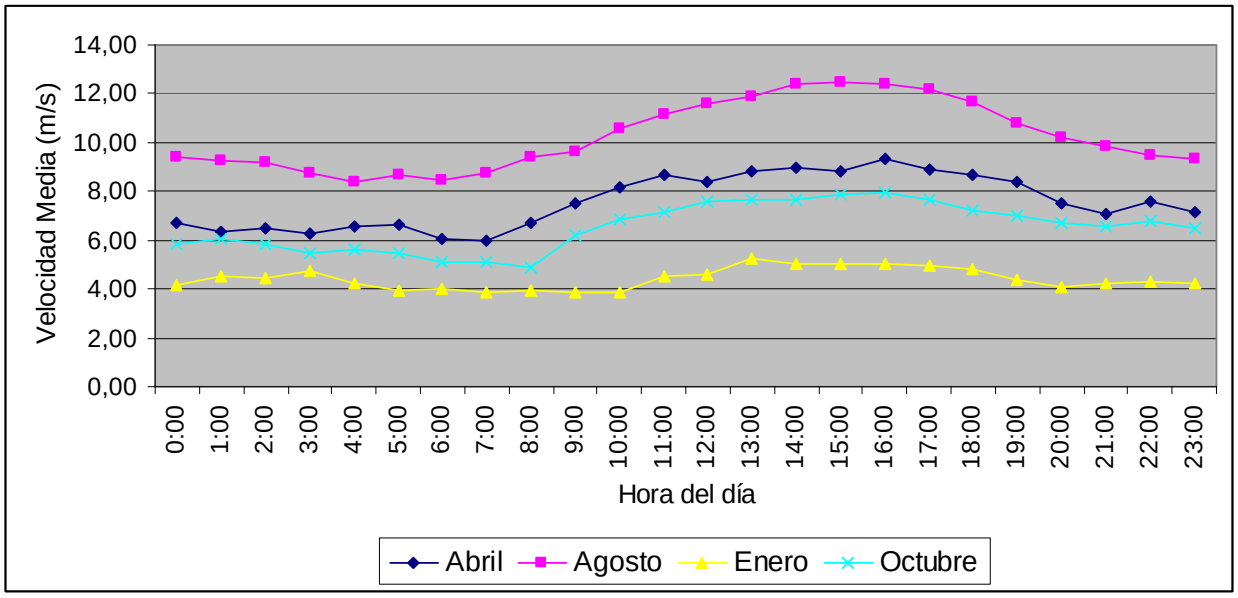

Figura 2.8:. Velocidades Medias Horarias por mes. Estación GC0110. Año 2008

2.4.2 Distribuciones de frecuencia.

Aparte de las distribuciones de la velocidad del viento en el tiempo es importante conocer el número de horas por mes o por año durante las cuales ocurre una determinada velocidad o dirección del viento, es decir, la distribución de frecuencias de velocidad y dirección (Rosa del viento).

- Distribución de frecuencia de velocidades.

Para la distribución de frecuencia de velocidades se debe en primer lugar dividir el dominio de la velocidad del viento en un número de intervalos, normalmente de un ancho de 1m/s. Entonces se procede a determinar el número de datos, de los recopilados de la campaña de

[19] Ver código de estaciones en el capítulo 7

medida, que se encuentran en cada uno de los intervalos. Este número de expresará finalmente en tanto por ciento (frecuencias). La representación de dichas frecuencias constituye el histograma de frecuencias de la velocidad del viento. (Figura 2.9)

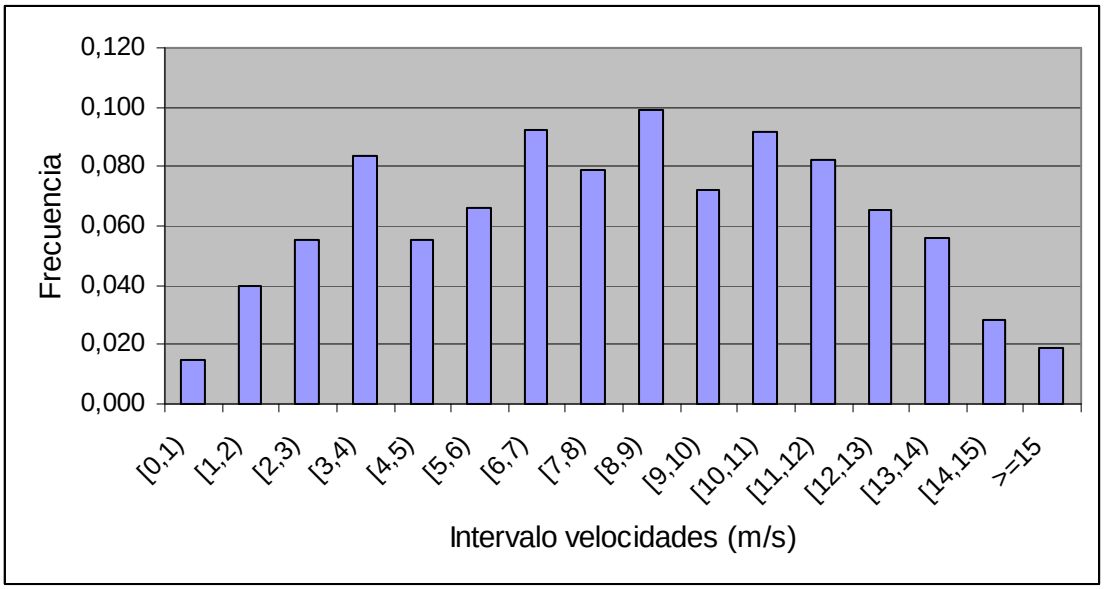

Figura 2.9:Distribución de frecuencia de velocidades. GC0110. Año 2008

A menudo es importante conocer el tiempo o frecuencia en el cual la velocidad del viento es más pequeña que una velocidad dada (p.e. velocidad de arranque de un aerogenerador), o bien conocer la frecuencia en la que la velocidad del viento es superior a una dada (p.e. velocidad nominal del aerogenerador). Para estos casos la información directa viene dada por la distribución de frecuencias acumuladas. (Figura 2.10).

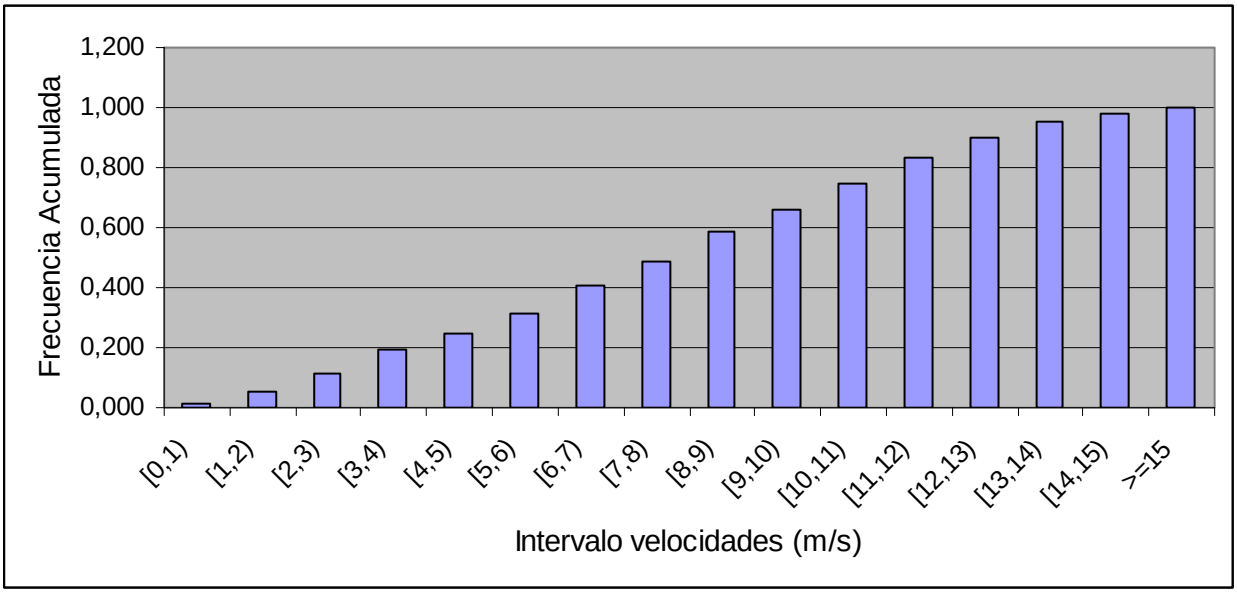

Figura 2.10:Distribución de Frecuencias acumuladas de velocidades. GC0110. Año 2008

• Distribución de frecuencia de Direcciones.

Para la distribución de frecuencia de direcciones se dividen los 360º en sectores de direcciones de tamaño determinado. En el ejemplo que se representa en la figura 2.11 se ha dividido en 16 sectores. En el perímetro se exponen la frecuencia relativa para cada uno éstos e internamente se expresa la velocidad media para cada sector. Con la representación de ambos datos: frecuencia de direcciones e intensidad del viento según la dirección se podría prever el potencial energético según cada dirección del viento.

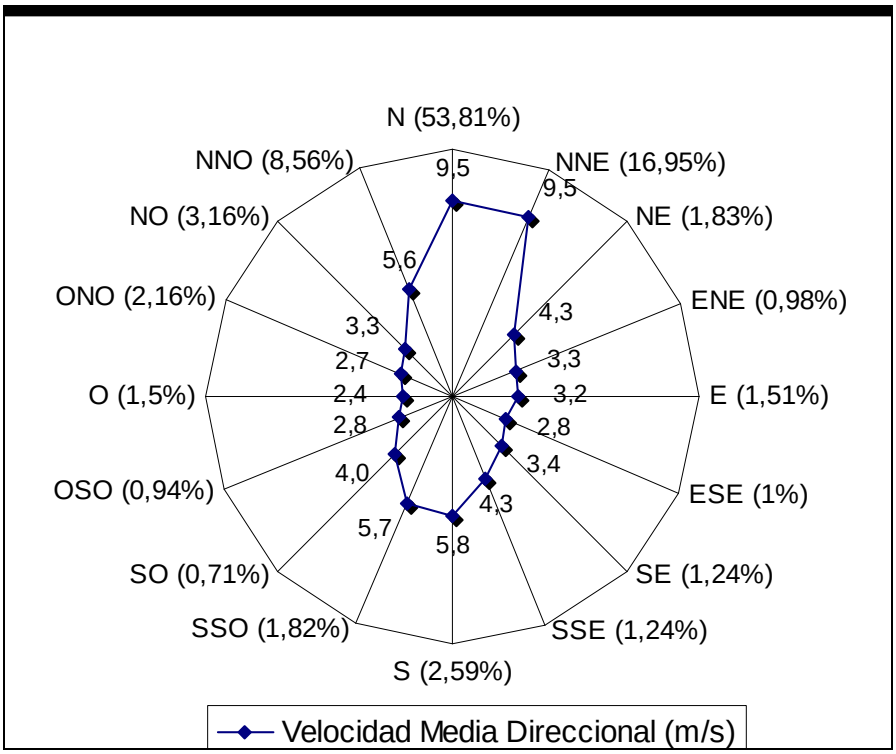

Figura 2.11:Distribución de Frecuencia de Direcciones (Rosa de lo vientos). GC0110. Año 2008.

2.5 Representación matemática de los regímenes de viento.

En el análisis estadístico del viento con la finalidad de evaluar la energía extraíble del mismo mediante máquinas eólicas es habitual trabajar con funciones de densidad de probabilidad continuas que se ajusten a los datos experimentales (Figura 2.12).

Cuando no se puede conocer de antemano los valores medidos de una cierta variable de interés, en este caso la velocidad del viento. durante un intervalo de tiempo determinado, es práctico describir esta variable como una variable aleatoria, representada por una letra mayúscula tal como *V*. Esta variable aleatoria se refiere a la población. La colección de todos los posibles valores de la población se denomina espacio muestral S. Las medidas en *V*, se representan por letras minúsculas tales como *v*. Un conjunto de estas medidas es la muestra. Entonces, una muestra es un subconjunto del espacio muestral S.

El aspecto de la incertidumbre de la variable aleatoria *V* es modelado por una distribución estadística de probabilidad caracterizada por una función $f(v,\theta)$ que recibe el nombre de función de densidad de probabilidad. La función de densidad de probabilidad de una variable aleatoria

continua *V* se define formalmente de la siguiente manera [47]: Si existe una función $f(v,\theta)$ tal que

$$f(v,\theta) \geq 0, \quad -\infty \leq v < \infty,$$

(Ec 2-1)
$$\int_{-\infty}^{\infty} f(v,\theta)dv = 1$$

$$P(a \leq V \leq b) = \int_a^b f(v,\theta)dv$$

para cualesquiera *a* y *b*, entonces $f(v,\theta)$ es la función de densidad de probabilidad de la variable aleatoria continua *V.*

Como señala Peña (1995) [48], la función de densidad representa una aproximación muy útil para calcular probabilidades partiendo de un histograma: en primer lugar es mucho más simple, permite sustituir la tabla completa de valores de la distribución de frecuencias por la ecuación matemática de $f(v,\theta)$; en segundo lugar es más general, trata de reflejar no el comportamiento de una muestra concreta, sino la estructura de distribución de los valores de la variable a largo plazo; en tercer lugar es más operativa, permite obtener probabilidades de cualquier suceso.

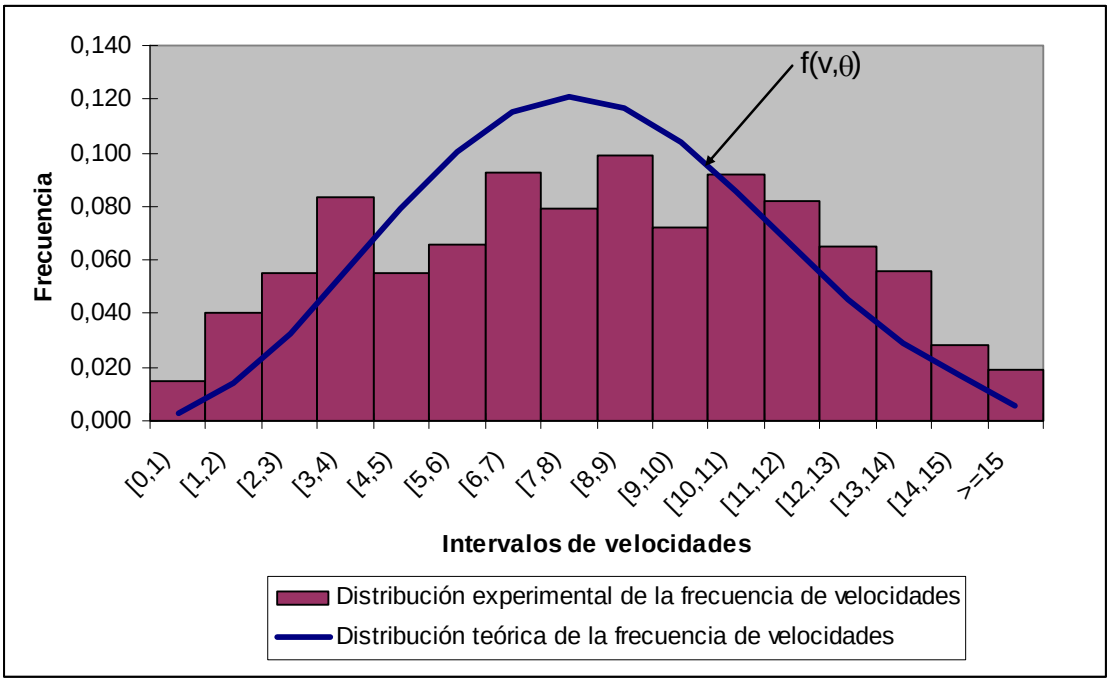

Figura 2.12:Densidad de probabilidad experimental y teórica. Estación GC0110. Año 2008

$f(v,\theta)$ constituye una familia de funciones de densidad de probabilidad, dependientes de los valores que pueden tomar los parámetros θ en su espacio parametral Ω.

De igual manera, la función de distribución acumulativa de una variable aleatoria continua V (Figura 2.13) es la probabilidad de que V tome un valor menor o igual a algún valor v específico. Esto es,

(Ec 2-2) $$P(V \le v) = F(v;\theta) = \int_0^v f(v,\theta)dv$$

La distribución acumulativa $F(v;\theta)$, es una función lisa no decreciente de los valores de la variable aleatoria con las siguientes propiedades [47]:

$$F(0,\theta) = 0,$$
$$F(\infty;\theta) = 1,$$
$$P(a \le V \le b) = F(b;\theta) - F(a;\theta),$$
$$dF(v,\theta)/dv = f(v;\theta)$$

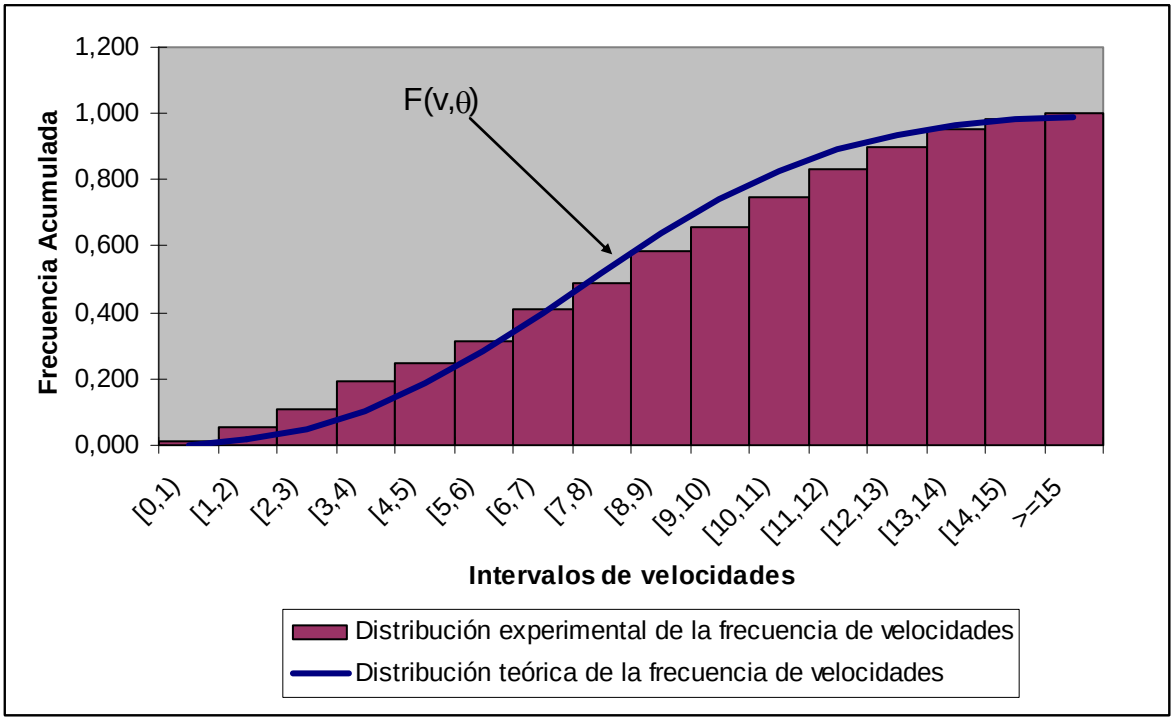

Figura 2.13:Distribución acumulada experimental y teórica. Estación GC0110. Año 2008

La estimación de los parámetros θ involucra el uso de los datos muestrales en conjunción con alguna estadística.

Aunque existen múltiples funciones de densidad continuas que se han empleado en el estudio de fenómenos aleatorios en disciplinas como la ingeniería y las ciencias aplicadas o bien los negocios y la economía [49-53], algunas de las funciones que en mayor medida han sido utilizadas en el análisis estadístico de la energía eólica son las siguientes:

- ✓ Gamma Generalizada de 3 parámetros
- ✓ Gamma de 2 parámetros
- ✓ Weibull de 3 y 2 parámetros
- ✓ Rayleigh de 1 parámetro
- ✓ Beta de 3 parámetros
- ✓ Lognormal de 2 parámetros
- ✓ Gaussiana Inversa de 2 parámetros
- ✓ Mixta de Weibull de 2 parámetros.

Estas funciones fueron comparadas por Carta, J.A. et al [54] en un caso de estudio en las islas Canarias

Los modelos que en el pasado se han aplicado al análisis estadístico del viento han revelado el inconveniente de no representar a las distribuciones que contienen altas frecuencias de velocidades nulas. Para solventar este problema Takle y Brown (1978) [55], definieron la llamada distribución híbrida, *g(v),* de la siguiente manera:

(Ec 2-3) $$g(v) = \theta_0 \cdot \delta(v) + (1-\theta_0) \cdot f(v)$$

donde:

$$\delta(v) = \begin{cases} 1 & \text{Para } v = 0 \\ 0 & \text{Para } v \neq 0 \end{cases}$$

θ_o es la probabilidad de observación de la velocidad de viento nula y *f(v)* es la función de densidad de probabilidad estándar, que para Takle y Brown (1978) [55] era la distribución de

Weibull de 2 parámetros y para Auwera *et al* (1980)[20] [56] la distribución Gamma generalizada de 3 parámetros..

La correspondiente función de distribución *G(v)*, viene dada, según Takle y Brown (1978) [55], por:

$$G(v) = \begin{cases} P(V \le v) = \theta_0 + (1-\theta_0)\cdot F(v) & \text{para } v \ge 0 \\ 0 & \text{para otro valor de } v \end{cases}$$

donde *F(v)* es la función de distribución de la función de densidad de probabilidad *f(v).*

2.5.1 Número efectivo de observaciones.

Cuando las observaciones de la muestra de viento $V_1,\ldots,V_n$ se recogen a lo largo del tiempo es frecuente la aparición de dependencia, como puede observarse en la Figura 2.14 En este trabajo se considerará que las velocidades de viento son variables aleatorias. Sin embargo, esta cuestión sólo es considerada explícitamente por muy pocos de los autores [16, 57-58], que han publicado artículos relativos a la estimación de distribuciones de la velocidad del viento.

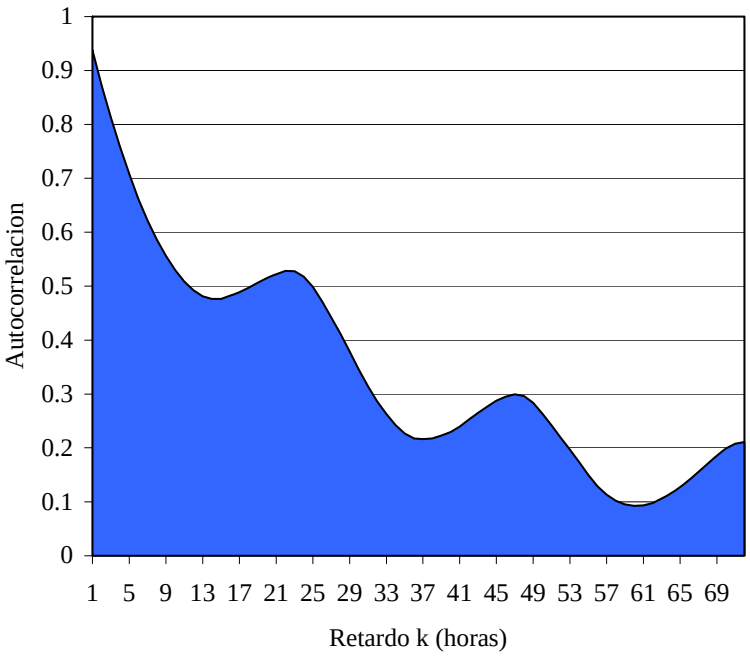

Figura 2.14:Función de autocorrelación.

[20] Auwera *et al* (1980) [56], denominan Ley de distribución de Weibull de tres parámetros a la normalmente reconocida como Ley de distribución Gamma Generalizada de tres parámetros.

Conradsen y Nielsen, (1984) [57] parten de la hipótesis que los parámetros estimados utilizando datos de viento dependientes no difieren de los parámetros estimados utilizando datos de viento independientes. Sin embargo, según dichos autores, las expresiones que proporcionan los errores estándar de los parámetros deben ser corregidos utilizando el número de datos de viento independientes. Corotis *et al*. (1977) [16], Conradsen y Nielsen, (1984) [57] y Brett y Tuller, (1991) [58], utilizan el denominado "número efectivo de observaciones", n^*, propuesto por Bayley y Hammersley (1946) [59] (Ec 2-4).

(Ec 2-4) $$n^* = \left[\frac{1}{n} + \frac{2}{n^2} \sum_{j=1}^{n-1} (n-j) r(j) \right]^{-1}$$

donde n es el número total de observaciones, y $r(j)$ representa el coeficiente de autocorrelación lineal de orden j, y viene dado por (Ec 2-5).

(Ec 2-5) $$r(j) = \frac{\sum_{i=j+1}^{n} (v_i - m_1')(v_{i-j} - m_1')}{\sum_{i=1}^{n} (v_i - m_1')^2}$$

En (Ec 2-5) m_1' es la velocidad media del viento, es decir, viene dada por (Ec 2-6).

(Ec 2-6) $$m_1' = \frac{\sum_{i=1}^{n} v_i}{n}$$

Obsérvese que si la autocorrelación es nula en (Ec 2-4), entonces n^* coincide con n.

Las expresiones (Ec 2-4) y (Ec 2-5) deben ser evaluadas numéricamente. Sin embargo, Bayley y Hammersley (1946) [59], Corotis *et al*. (1977) [16], Conradsen y Nielsen, (1984) [57] y Brett y Tuller, (1991) [58], proponen modelos simples para determinar la función de autocorrelación. Ellos asumen que la autocorrelación puede decaer de forma exponencial o de forma cosenoidal amortiguada.

Para una función de autocorrelación que decae exponencialmente Corotis *et al*. (1977) [16] indican que es posible estimar el número de observaciones independientes $n_i(T)$ de lectura en un tiempo especificado T[21] (Ec 2-7) ajustando una función exponencial a la autocorrelación [60]. Por tanto, si γ es una constante definida como el inverso del tiempo de autocorrelación, el

cual es el tiempo que necesita la función de autocorrelación para decaer hasta 1/e de su valor original[22].

(Ec 2-7) $$n_i(T) = \frac{\gamma T}{2\gamma T - 2e^{-\gamma T} - 2}$$

Para la función de autocorrelación cosenoidal Bayley y Hammersley, (1946) [59] y Conradsen y Nielsen, (1984) [57], estiman un número efectivo de observaciones dado por (Ec 2-8).

(Ec 2-8) $$n^* \approx n\left[\frac{\sinh(\gamma\tau)}{\cosh(\gamma\tau)-\cos(\lambda\tau)} + \frac{1}{n}\frac{1-\cosh(\gamma\tau)\cos(\lambda\tau)}{\left(\cosh(\gamma\tau)-\cos(\gamma\tau)\right)^2}\right]^{-1} \approx n\frac{\cosh(\gamma\tau)-\cos(\lambda\tau)}{\sinh(\gamma\tau)}$$

donde γ y λ son constantes peculiares del autoregresivo proceso en consideración.

Para seleccionar los intervalos de toma de datos de tal manera que pueda aceptarse, con un nivel de significación de 0.05, la hipótesis nula que afirma la existencia de independencia entre ellos, deberá utilizarse un contraste de autocorrelación. Box y Pierce (1970) [61] proponen un test, posteriormente mejorado por Ljung y Box (1978) [62], que utiliza el estadístico siguiente (Ec 2-9)

(Ec 2-9) $$Q = n(n+2)\sum_{k=1}^{z}\frac{r^2(k)}{n-k}$$

Bajo la hipótesis nula, *Q* se distribuye asintóticamente como una χ^2 con *z*-1[23] grados de libertad, siempre y cuando las observaciones sean independientes e idénticamente distribuidas. Si se cumple lo anterior, la inferencia realizada con el estadístico (Ec 2-9) es adecuada, por lo que si Q< $\chi^2_{z,\alpha}$, entonces se acepta la hipótesis nula. *r*(*k*) representa el coeficiente de autocorrelación lineal de orden *k*, y viene dado por (Ec 2-5), donde *j*=*k*.
Sin embargo, según Lobato *et al* (2001) [63], la realidad es que para muchas series de tiempo el supuesto de independencia es cuestionable, pudiendo los datos no presentar correlación y

[21] Ejemplo 24 horas, cuando se desea calcular el número de horas independientes por día.
[22] e, es la base del logaritmo.
[23] Se ha considerado *z*<*n*/4.

ser estadísticamente dependientes [64], por lo que el estadístico (Ec 2-9) puede producir inferencias equivocadas. En conclusión, el contraste (Ec 2-9) es válido si y solo si el proceso es Gaussiano. Es decir, si $\left(\sqrt{n}\right)r$ se distribuye asintóticamente como una *N*(0,I). Por tanto, si la hipótesis de normalidad es rechazada por los datos[24], o que, sin serlo totalmente, hay cierta evidencia de que puede no ser cierta es necesario realizar ciertas operaciones. Si la distribución es unimodal[25] y asimétrica, la solución más simple y efectiva suele ser transformarlos para convertirlos en normales.

Existen diversos tipos de transformaciones [65]. Entre éstas se puede señalar la siguiente familia de transformaciones que han sugerido Box y Cox (1964) [66] para conseguir la normalidad:

$$\text{(Ec 2-10)} \quad v^{(\lambda)} = \begin{cases} \dfrac{(v+m)^{\lambda}-1}{\lambda} & (\lambda \neq 0) \quad (v > -m) \\ \ln(v+m) & (\lambda = 0) \quad (m > 0) \end{cases}$$

donde λ es el parámetro de la transformación y *m* una constante

Esta transformación es recomendable para conjuntos de datos en donde no existan datos negativos, es decir, para conjuntos de datos que sean mayor o igual a cero, como ocurre con las velocidades del viento.

El parámetro λ se estima a partir de los datos y *m* se elige de forma que *v*+*m* sea siempre positiva.

Box y Cox (1964) [66], presentaron un algoritmo que permitiría la selección de la transformación apropiada. Suponiendo un valor positivo de *m* y que existe un valor de λ que transforma a la variable en normal, la relación entre el modelo para los datos originales *v* y para los transformados $v^{(\lambda)}$ será:

[24] Mediante la aplicación de un contraste de normalidad.

[25] Si la distribución es bimodal se precisa investigar la presencia de heterogeneidad mediante el contraste de Wilcoxon [48]

(Ec 2-11) $$f(v) = f\left[v^{(\lambda)}\right]\left|\frac{dv^{\lambda}}{dv}\right|$$

como:

(Ec 2-12) $$\frac{dv^{\lambda}}{dv} = \frac{\lambda\left(v+m\right)^{\lambda-1}}{\lambda} = \left(v+m\right)^{\lambda-1}$$

y suponiendo que v^{λ} es $N(\mu,\sigma)$ para cierto λ, la función de densidad de las variables originales será:

(Ec 2-13) $$f(v) = \frac{1}{\sigma\sqrt{2\pi}} v^{\lambda-1} \exp\left\{-\frac{1}{2\sigma^2}\left[\frac{\left(v+m\right)^{\lambda}-1}{\lambda} - \mu\right]^2\right\}$$

Por tanto, la función de densidad conjunta de $V = \left(v_1,\ldots,v_n\right)$ será, por la independencia de las observaciones:

(Ec 2-14) $$f(V) = \frac{1}{\sigma^n\left(\sqrt{2\pi}\right)^n}\left[\prod_{i=1}^{n}\left(v_i+m\right)^{\lambda-1}\right]\exp\left\{-\frac{1}{2\sigma^2}\sum\left[\frac{\left(v_i+m\right)^{\lambda}-1}{\lambda} - \mu\right]^2\right\}$$

y la función soporte o logaritmo de la verosimilitud

(Ec 2-15) $$L(\lambda;\mu,\sigma^2) = -\frac{n}{2}\ln\sigma^2 - \frac{n}{2}\ln 2\pi + \left(\lambda-1\right)\sum\ln\left(v_i+m\right) - \frac{1}{2\sigma^2}\sum\left[\frac{\left(v_i+m\right)^{\lambda}-1}{\lambda} - \mu\right]^2$$

Para obtener el máximo de esta función se utiliza que, para λ fijo, los valores de σ^2 y μ que maximizan la verosimilitud (o el soporte) son, derivando e igualando a cero:

(Ec 2-16) $$\hat{\mu}(\lambda) = \frac{1}{n}\sum\left[\frac{\left(v_i+m\right)^{\lambda}-1}{\lambda}\right]$$

(Ec 2-17) $$\hat{\sigma}^2(\lambda) = \frac{1}{n}\sum\left[\frac{\left(v_i+m\right)^{\lambda}-1}{\lambda} - \hat{\mu}\left(\lambda\right)\right]^2$$

Al sustituir (Ec 2-16) y (Ec 2-17) en (Ec 2-15) se obtiene la llamada función de verosimilitud concentrada en λ. cuya expresión, prescindiendo de constantes es:

$$\text{(Ec 2-18)} \quad L(\lambda;\hat{\mu},\hat{\sigma}^2) = -\frac{n}{2}\ln\hat{\sigma}^2(\lambda) + \left(\lambda - 1\right)\sum \ln\left(v_i + m\right)$$

El valor de $\hat{\lambda}$ que maximice (Ec 2-18) es el estimador *MV* de la transformación.

2.6 Pruebas de hipótesis estadísticas.

Una vez seleccionada una distribución de densidad de probabilidad y estimados sus parámetros θ para representar una población de viento, se tiene que tomar decisiones sobre la misma, partiendo de la información muestral. Tales decisiones se denominan decisiones estadísticas.

Para llegar a tomar decisiones, conviene hacer determinados supuestos o conjeturas acerca de las poblaciones que se estudian. Tales supuestos que pueden ser o no ciertos se llaman hipótesis estadísticas y, en este caso, lo son sobre las distribuciones de probabilidad de las poblaciones de viento.

En este trabajo se formula la hipótesis de que las distribuciones teóricas propuestas se ajustan a las distribuciones empíricas, es decir, aquellas que se obtienen de los datos muestrales. Esta hipótesis se le denomina hipótesis nula y se representa por H_0. Cualquier hipótesis que difiera de una hipótesis dada se llama hipótesis alternativa.

Los procedimientos que facilitan el decidir si una hipótesis se acepta o se rechaza o el determinar si las muestras observadas difieren significativamente de los resultados esperados se llaman ensayos de hipótesis, ensayos de significación o reglas de decisión.

En la tabla 2.1 se presentan las posibles decisiones que pueden tomarse con respecto a la hipótesis nula H_0 y las consecuencias que pueden originarse como resultado del verdadero estado de la naturaleza. [68].

Tabla 2.1: Cuadro de decisiones

Decisión	Hipótesis nula H_0	
	Verdadera	Falsa
Rechazar	Error tipo I (α)	Decisión correcta
Aceptar	Decisión correcta	Error tipo II (β)

Si se rechaza una hipótesis cuando debería ser aceptada, se dice que se comete un error del Tipo I. Si, por el contrario, se acepta una hipótesis que debería ser rechazada, se dice que se comete un error del Tipo II. En cualquiera de los dos casos se comete un error al tomar una decisión equivocada.

Para que el ensayo de hipótesis sea bueno, debe diseñarse de forma que minimice los errores de decisión. Esto no es tan sencillo como pueda parecer puesto que para un tamaño de muestra dado, un intento de disminuir un tipo de error, va generalmente acompañado por un incremento en el otro tipo de error. En la práctica, un tipo de error puede tener más importancia que el otro, y así se tiende a conseguir poner una limitación al error de mayor importancia. La única forma de reducir al tiempo ambos tipos de error es incrementar el tamaño de la muestra, lo puede ser o no posible.

La probabilidad máxima con la que en el ensayo de hipótesis se puede cometer un error del Tipo I se le llama nivel de significación del ensayo. Esta probabilidad se representa frecuentemente por α[26]; generalmente se fija antes de la prueba, de modo que los resultados obtenidos no influyen en la elección. La probabilidad de cometer un error del Tipo II se representa generalmente por β.

2.7 Pruebas de bondad de ajuste.

En las pruebas de bondad de ajuste se compara los resultados de una muestra aleatoria con aquellos que se espera observar si la hipótesis nula es correcta. La comparación se hace mediante la clasificación de los datos que se observan en cierto numero de categorías y entonces comparando las frecuencias observadas con las esperadas para cada categoría.

[26] En la práctica se acostumbra a utilizar niveles de significación del 0.05 ó 0.01, aunque igualmente pueden emplearse otros valores.

Para un tamaño específico del error de Tipo I, la hipótesis nula será rechazada si existe una diferencia suficiente entre las frecuencias observadas y las esperadas.
Supóngase que v_1, v_2, v_3,....., v_n son observaciones independientes de una variable aleatoria V con función de distribución $F(v)$ desconocida. Considérese la hipótesis nula

(Ec 2-19) $$H_0 : F(v) = F_0(\theta; v)$$

donde el modelo de probabilidad propuesto $F_0(\theta;v)$ se encuentra especificado, de manera completa, con respecto a todos los parámetros θ.
Existen diversos test de ajuste [68]. Sin embargo, en el análisis estadístico del viento, son cuatro las pruebas de bondad de ajuste que se han utilizado: la prueba Chi-cuadrado de Pearson [56; 57; 69], la prueba de Kolmogorov-Smirnov o prueba *K-S.* [69-71], la prueba de Anderson-Darling [72] y la prueba del gráfico de probabilidad [73].

2.7.1 Prueba de Chi2.

El contraste de ajuste más antiguo es el contraste de Pearson, cuya idea es comparar las frecuencias observadas en un histograma con las especificadas por el modelo teórico que se contrasta. El test Chi2 se aplica a todo tipo de distribuciones, discretas y continuas.
La hipótesis H_0 que se utilizará en este trabajo se basa en el hecho de que los datos de la variable v provienen de un determinado modelo, del que se conoce su forma, pero no los parámetros, que se estiman a partir de los datos.
Aquí, se supone que se tiene una muestra $V = (v_1, \ldots, v_n)$ aleatoria simple relativamente grande [27]de una variable continua. Para realizar el contraste se procede de la siguiente manera:

- Se agrupan los n datos en k clases. Las clases deben ser elegidas para que tengan todas igual probabilidad bajo la hipotética distribución $F(v)$ [65; 68].
  Mann y Wald (1942) [74] encontraron que para una muestra de tamaño n (grande) y nivel de significación α, se deberá usar un número de clases dado, aproximadamente, por (Ec 2-20). Sin embargo, Schorr (1974) [75], indica que el k “optimo” es más pequeño que el dado por (Ec 2-20) y recomienda tomar un número de clases dado por $k = 2n^{2/5}$.

[27] De acuerdo con Canavos (1988), la aplicabilidad de la prueba de bondad de ajuste Chi2 es cuestionable cuando se tienen muestras de tamaño muy grande, ya que es casi seguro el rechazar la

(Ec 2-20) $$k = 4\left[\frac{2n^2}{c(\alpha)^2}\right]^{\frac{1}{5}}$$

donde c(α) es el punto-α superior de la distribución normal estándar.

A las frecuencia observadas en la muestra de clase i les llamaremos O_i

- Si p_i es la probabilidad que el modelo propuesto asigna a cada clase, la frecuencia esperada de la clase *i* vendrá dada por $E_i = np_i$
- Se calcula la discrepancia entre las frecuencias observadas y la esperadas mediante (Ec 2-21)

(Ec 2-21) $$\chi^2 = \sum_1^k \frac{\left(O_i - E_i\right)^2}{E_i}$$

que se distribuye aproximadamente como una χ^2 cuando el modelo es correcto. Sus grados de libertad vienen dados por *k*-*r*-1, donde *r* es el número de parámetros que se han estimado en el modelo haciendo uso del método de máxima verosimilitud [65].

Se rechaza el modelo cuando la probabilidad de obtener una discrepancia mayor o igual a la observada sea suficientemente baja. Es decir, cuando:

(Ec 2-22) $$\chi^2 \geq \chi^2_\alpha(k - r - 1)$$

Para un cierto α pequeño.

2.7.2 Prueba de *K-S*.

Una prueba de bondad de ajuste más apropiada que la chi-cuadrada cuando $F_0(v)$ es continua y los parámetros de la distribución no son estimados a partir de la muestra[28], es la basada en la estadística de Kolmogorov-Smirnov. La prueba de *K-S* no necesita que los datos se encuentren

hipótesis nula debido a que es muy difícil especificar una H_0 lo suficientemente cerca de la verdadera distribución.

agrupados y es aplicable a muestras de tamaño pequeño. Sin embargo, el test *K-S* es una distribución libre en el sentido que los valores críticos no dependen de la distribución especifica que se este ensayando.

Ésta se basa en una comparación entre las funciones de distribución acumulativa que se observan en la muestra ordenada y la distribución propuesta bajo H_0. Si esta comparación revela una diferencia suficientemente grande entre las funciones de distribución muestral y propuesta, entonces la hipótesis nula de que la distribución es $F_0(v)$, se rechaza.

Considérese la hipótesis nula por (Ec 2-19), en donde $F_0(v)$, se especifica de forma completa. Denomínese por $V_{(1)}$, $V_{(2)}$, ..., $V_{(n)}$ a las observaciones ordenadas de una muestra aleatoria de tamaño *n* y defínase la función de distribución acumulativa muestral como:

(Ec 2-23) $$S_n(v) = \begin{cases} 0 & v < v_{(1)} \\ k/n & \mathrm{v}_{(k)} \le v < v_{(k+1)} \\ 1 & v > v_{\mathrm{n}} \end{cases}$$

Ya que $F_0(v)$ se encuentra completamente especificada, es posible evaluar a $F_0(v)$ para algún valor deseado *v*, y entonces comparar este último con el valor correspondiente de $S_n(v)$. Si la hipótesis nula es verdadera, entonces es lógico esperar que la diferencia sea relativamente pequeña. La estadística *K-S* se define como:

(Ec 2-24) $$D_n = \max_v \left| S_n(v) - F_0(v) \right|$$

La estadística D_n tiene una distribución que es independiente del modelo propuesto bajo H_0. Por esta razón, se dice que D_n es una estadística independiente de la distribución. Lo anterior implica que la función de distribución de D_n puede evaluarse sólo en función del tamaño n de la muestra y después usarse para cualquier $F_0(v)$.

La función que entra en el cálculo de la significación puede escribirse como la suma siguiente [*65,76*]:

(Ec 2-25) $$Q_{K-S}(\lambda) = 2\sum_{j=1}^{\infty} (-1)^{j-1} e^{-2j^2\lambda^2}$$

[28] Cuando los parámetros son estimados a partir de los datos muestrales es necesario utilizar test basados en funciones de distribución empíricas que se han desarrollado para distribuciones concretas (D'Agostino y Stephens, 1986)

En términos de esta función, la significación de un valor observado de D_n viene dado aproximadamente [76] por la fórmula (Ec 2-26).

(Ec 2-26) $$P(D_n > d_\alpha) = \alpha = Q_{K-S}\left(\left[\sqrt{n} + 0.12 + 0.11/\sqrt{n}\right] D_n\right)$$

De acuerdo con lo anterior, la hipótesis H_0 se rechaza si para algún valor v observado el valor de D_n se encuentra dentro de la región critica de tamaño α.

2.7.3 Prueba de Anderson-Darling.

El test de Anderson-Darling [68] se usa para analizar si una muestra de datos proviene de una población con una distribución específica. Se trata de una modificación del test de Kolmogorov-Smirnov y proporciona más peso a las colas que el test de *K-S.* El test de Anderson-Darling hace uso de la distribución específica para calcular los valores críticos. Esto tiene la ventaja de conseguir un más sensible test y la desventaja que los valores críticos deben ser calculados para cada distribución.

El test de Anderson-Darling se define como

(Ec 2-27) $$A^2 = -n - S$$

Donde

(Ec 2-28) $$S = \sum_{i=1}^{n} \frac{(2i-1)}{n}\left[\ln F(v_i) + \ln(1 - F(v_{n+1-i}))\right]$$

y F es la función de distribución acumulativa de la distribución específica. Debe tenerse en cuenta que v_i son los datos ordenados.

Los valores criticos del test de Anderson-Darling dependen de la distribución especifica que esta siendo analizada. Tablas de valores y fórmulas han sido publicadas por D'Agostino y Stephens, (1986) [68] para unas pocas distribuciones especificas (normal, logaritmo-normal, exponencial, Weibull y logística). Para una distribución dada, el estadístico de Anderson-Darling debe ser multiplicado por una constante, la cual normalmente depende del tamaño de la muestra, n.

2.7.4 Prueba de los gráficos de probabilidad.

Los gráficos de probabilidad (probability plots) pueden ser generados para diversas distribuciones para ver cual proporciona el mejor ajuste. El coeficiente de correlación asociado con el ajuste lineal a los datos en el gráfico de probabilidad R^2 es una medida de la bondad del ajuste [77]. El gráfico de probabilidad que genere el R^2 más alto proporcionará la mejor elección,

El R^2, ajustado por los grados de libertad (*DF=n-np*), vendrá dado por (Ec 2-29), donde Od_i son las ordenadas de los datos, Op_i son las ordenadas del modelo, $\overline{Od}$ la media de los valores Od_i, *n* el número de puntos de datos y *np* el número de parámetros utilizados en las correspondientes leyes de distribución de probabilidad utilizadas.

$$\text{(Ec 2-29)} \quad R^2 = 1 - \frac{(n-1)\sum_{i=1}^{n}(Od_i - Op_i)^2}{(DF-1)\sum_{i=1}^{n}(Od_i - \overline{Od})^2} \quad ; \quad i = 1,\ldots,n$$

2.8 Valoración de la energía eólica.

Para caracterizar las disponibilidades de energía eólica se debe distinguir [39] entre energía eólica disponible, que es la energía que podría transformar una máquina eólica ideal de rendimiento unidad, y la energía eólica recuperable, que depende de las características del sistema de conversión utilizado.

2.8.1 Energía eólica disponible.

La potencia eólica disponible a través de una superficie de sección circular *A* perpendicular al flujo de viento *v* viene dada por el flujo de la energía cinética por unidad de tiempo (Ec 2-30)

$$\text{(Ec 2-30)} \quad P_d = \frac{1}{2}\cdot Q\cdot v^2 = \frac{1}{2}\cdot\left(\rho\cdot \mathrm{A}\cdot v\right)\cdot v^2 = \frac{1}{2}\cdot\rho\cdot \mathrm{A}\cdot v^3$$

donde ρ es la densidad del aire, que varía con la altitud y con las condiciones atmosféricas. Esta variación puede ser del orden del 7% [34] sobre un valor medio que se toma normalmente

de 1.225 kg/m^3. Por tanto, la potencia del viento depende de la densidad del aire, de la superficie sobre la que incide y de la velocidad del viento, por estar ésta elevada a la tercera potencia en la expresión (Ec 2-30). Esta enorme dependencia de la velocidad del viento queda claramente reflejada en la figura 2.15.

Un método para caracterizar la potencia eólica disponible en distintos lugares de interés, por medio del cual se pueden comparar éstos, consiste en utilizar la potencia eólica media disponible por unidad de superficie barrida (Ec 2-31):

(Ec 2-31) $$\frac{\overline{P}_d}{\mathrm{A}} = \frac{1}{2} \cdot \rho \cdot \overline{v^3}$$

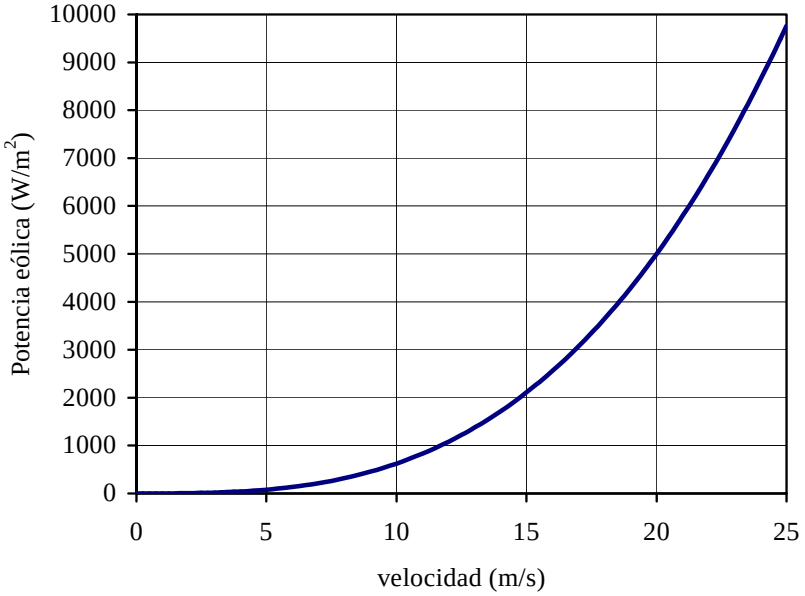

Figura 2.15:Dependencia de la potencia del viento de la velocidad del mismo

Si se conoce únicamente la velocidad media del viento y se desea obtener la potencia eólica media disponible, es necesario disponer de información suplementaria sobre la función de densidad de probabilidad de viento *f*(v). De forma más precisa, la velocidad media del viento es el momento de primer orden de la función de densidad de probabilidad

(Ec 2-32) $$\overline{v} = \int_0^{\infty} v f(v) dv$$

y la media del cubo de la velocidad es el momento de orden tres respecto del origen

(Ec 2-33) $$\overline{v^3} = \int_0^\infty v^3 f(v) dv$$

(Ec 2-34) $$\overline{E}_d = \left(\frac{\overline{P}_d}{\mathrm{A}}\right)\frac{N_h}{1000}\left(\frac{kWh}{m^2}\right)$$

A partir de la potencia eólica media disponible por unidad de superficie, dada por (Ec 2-31) es posible deducir la energía eólica disponible en un determinado periodo de tiempo (Ec 2-34), en kWh/m^2, multiplicando esta ecuación por el número de horas N_h contenidas en dicho periodo de tiempo y dividiendo por 1000.

Se define el factor de irregularidad [78] como la relación entre la energía eólica disponible calculada con (Ec 2-32) y la que se obtendría a partir del cubo de la velocidad media, resultando:

(Ec 2-35) $$K_e = \frac{\overline{v^3}}{\left(\overline{v}\right)^3}$$

De ensayos realizados en algunas estaciones meteorológicas en Gran Bretaña [78], se concluye que no se debe calcular la energía disponible utilizando el cubo de la velocidad media para un periodo de tiempo largo, aunque si sirve para periodos relativamente cortos.

2.8.1.1 Histogramas de densidad de energía.

- <u>Distribución de la densidad de energía aprovechable según la dirección del viento</u>

La distribución de la energía representa la aportación energética del viento en un emplazamiento dado según sea la dirección de éste. En esta representación no sólo se tendrá en cuenta la frecuencia de las direcciones, sino además la intensidad media del viento según cada una de éstas. Así por ejemplo, la energía aprovechable en un sector de dirección con frecuencia 10% y velocidad media de 8m/s es superior a la de otro sector, que aún teniendo una frecuencia de direcciones superior, p.e. el 15%, posea una velocidad media en el mismo inferior, p.e. 6m/s (Ver ecuación 2.39)

(Ec 2-36) $$\frac{1}{2}\rho V^3 t \Rightarrow \frac{1}{2}\rho \times 8^3 \times 8760 \times 0{,}1 > \frac{1}{2}\rho \times 6^3 \times 8760 \times 0{,}15 \; (\mathrm{W}/\mathrm{m}^2)$$

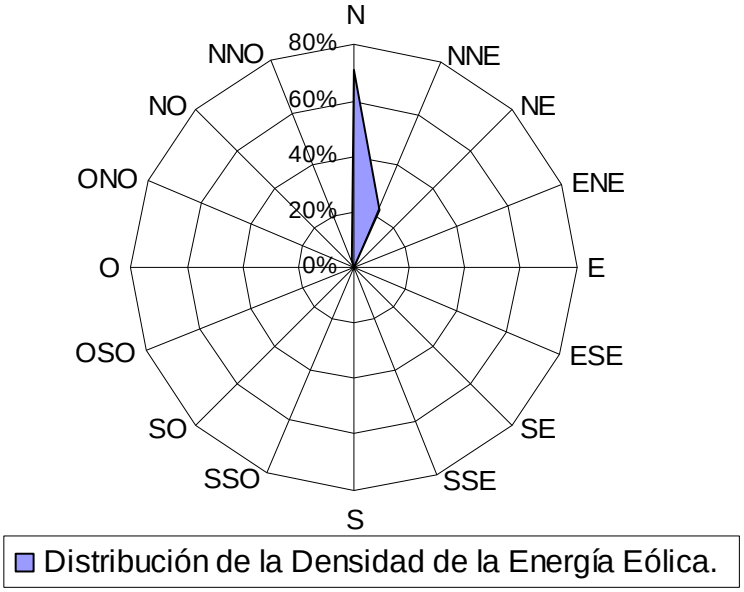

Figura 2.16:Distribución de la densidad de energía aprovechable según la dirección del viento. Estación GC0110. Año 2008

En la figura 2.11 se observa que la frecuencia del viento en la dirección Norte por ejemplo era del 53,1%; pero la densidad de energía aprovechable en dicho sector, según se refleja en la figura 2.16 es del 71%. Esto se debe a que la velocidad del viento en esa dirección es muy superior a la media del emplazamiento. Por ello es la importancia a la hora de distribuir sobre el terreno los aerogeneradores de un parque eólico, no sólo el considerar la distribución de direcciones sino conocer el aporte energético del viento en cada uno de los sectores de dirección.

- <u>Distribución de la densidad de energía según la velocidad del viento</u>

También, como señala Le Gouriérès (1983) [33], se pueden trazar los histogramas de probabilidad de energía en función de la velocidad del viento por intervalos de 1 m/s. Estos histogramas permiten advertir la importancia de los vientos de intensidad comprendida entre dos valores dados, bajo del punto de vista de la producción energética (figura. 2.17).

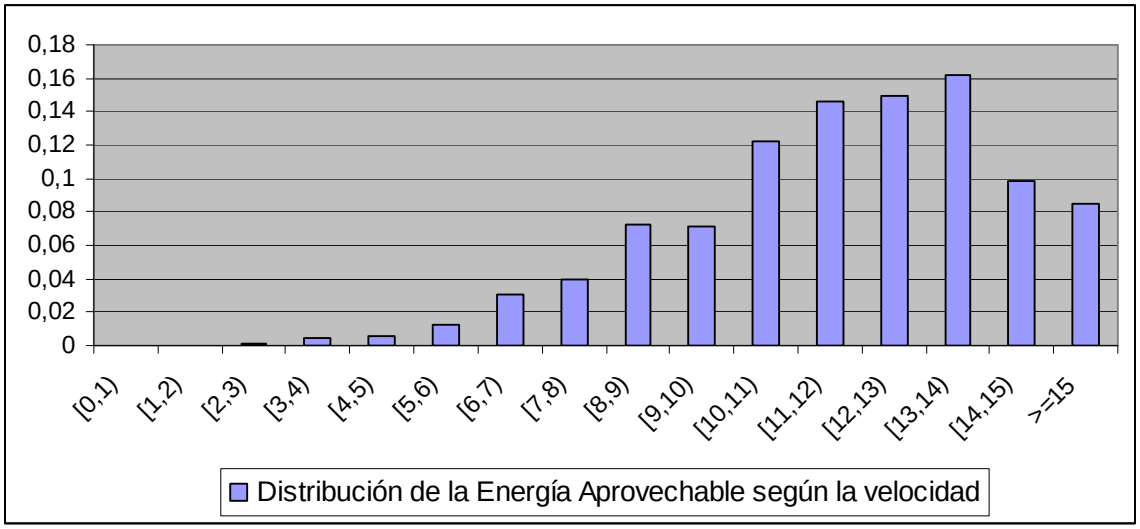

Figura 2.17:Distribución de la densidad de Energía Aprovechable según la velocidad del viento. Estación GC0110. Año 2008

La moda de la distribución de densidad de energía, es decir, la velocidad del viento a la cual la distribución de densidad de energía tiene un máximo proporciona la velocidad que proporciona mayor energía de la zona de estudio. Esta velocidad se denomina como velocidad de diseño de una turbina eólica, ya que la energía anual producida es normalmente máxima si una turbina eólica se diseña para operar a dicha velocidad.

2.8.2 Energía eólica máxima recuperable. Límite de Betz.

La potencia eólica que puede ser extraía del flujo de viento depende de la potencia eólica disponible y de las características de funcionamiento del dispositivo de extracción (Turbina eólica). Betz[29] demuestra que la potencia máxima de salida de un sistema ideal de conversión de energía eólica está limitada. Betz supone que la máquina eólica está colocada en un aire animado con una velocidad imperturbada v_1 y una presión p_0 “aguas arriba “ del rotor y con una velocidad v_2 y una presión p_0 “aguas abajo” de la misma. Como la producción de energía no se realiza más que a consta de la energía cinética, la velocidad v_2 es necesariamente inferior a v_1. Resulta de aquí que la vena fluida atraviesa el rotor alargándose (figura 2.18).

[29] La teoría global del motor eólico de eje horizontal fue establecida por Betz

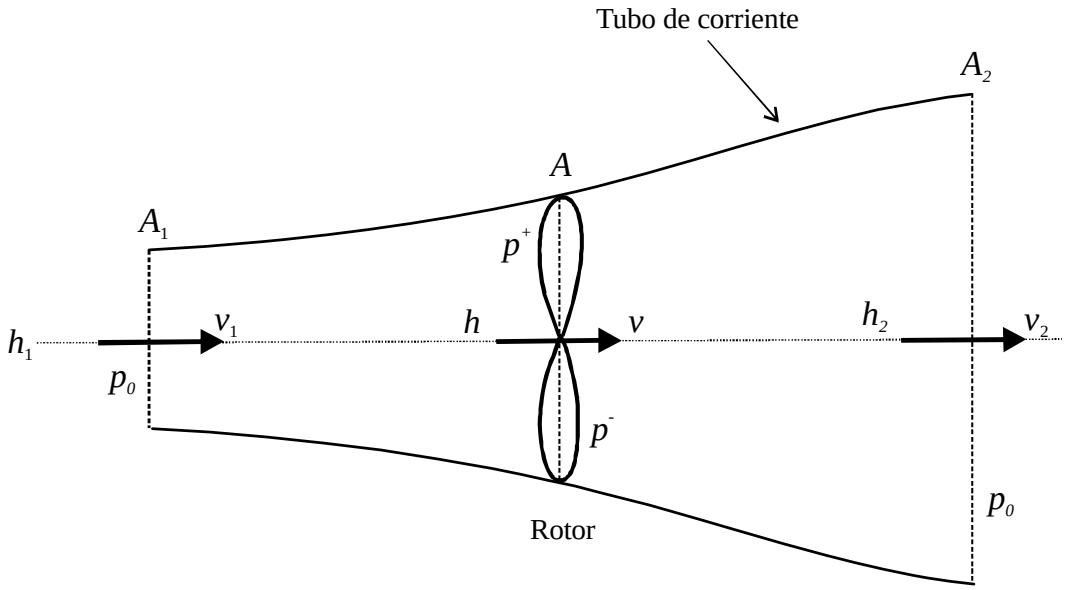

Figura 2.18:Flujo idealizado a través de una turbina eólica representada por un disco (rotor) no giratorio

De la aplicación de las ecuaciones básicas de la Mecánica de Fluidos se obtiene:

- <u>Ecuación de continuidad.</u>

Si se designa por la letra *v*, la velocidad del aire al paso del aeromotor, por A_1 y A_2 las secciones hacia el origen y hacia el final, de la vena y por *A* el área abarrida por la hélice, la ecuación de continuidad (admitiendo incompresibilidad del aire) puede escribirse:

(Ec 2-37) $$\rho A_1 v_1 = \rho A v = \rho A_2 v_2$$

- <u>Ecuación de la cantidad de movimiento.</u>

Según el teorema de Euler, la fuerza ejercida por el generador eólico sobre el aire en movimiento se dirige hacia delante y es igual en valor absoluto a:

(Ec 2-38) $$F = \rho Q\left(v_1 - v_2\right) = \rho A v\left(v_1 - v_2\right)$$

Esta fuerza *F* por otro lado se puede expresar en función de la sección del rotor y de la diferencia de presiones delante y detrás del mismo.

(Ec 2-39) $$F = A\left(p^{+} - p^{-}\right)$$

- Ecuación de Bernouilli.

Aplicando dos veces esta ecuación entre la sección 1 y la sección anterior del rotor y entre la sección posterior del rotor y la sección 2, se obtiene.

(Ec 2-40) $$\frac{1}{2}\rho v_1^2 + p_0 + \rho g h_1 = \frac{1}{2}\rho v^2 + p^{+} + \rho g h$$

(Ec 2-41) $$\frac{1}{2}\rho v^2 + p^{-} + \rho g h = \frac{1}{2}\rho v_2^2 + p_0 + \rho g h_2$$

Debido a la incompresibilidad del aire (ρ=cte) y a que la corriente de aire es horizontal ($h=h_1=h_2$). Por tanto, restando a (Ec 2-40) la expresión (Ec 2-41) se tiene:

(Ec 2-42) $$p^{+} - p^{-} = \frac{1}{2}\rho(v_1^2 - v_2^2)$$

Sustituyendo (Ec 2-42) en (Ec 2-39) se obtiene:

(Ec 2-43) $$F = A(p^{+} - p^{-}) = \frac{1}{2}\rho A(v_1^2 - v_2^2)$$

Igualando (Ec 2-38) y (Ec 2-43) se deduce:

(Ec 2-44) $$v = \frac{v_1 + v_2}{2}$$

La potencia absorbida por la fuera *F* (es decir el motor eólico) cuyo punto de aplicación se desplaza a la velocidad *v* respeto a las moléculas de aire en movimiento es, en estas condiciones:

(Ec 2-45) $$P = Fv = \frac{1}{4}\rho A(v_1^2 - v_2^2)(v_1 + v_2)$$

Con el propósito de proporcionar una referencia para esta potencia de salida, ésta se compara con la potencia de la corriente de aire libre que fluye a través de la misma sección de área *A*, sin que ninguna potencia mecánica sea extraída de ella. Esta potencia viene dada por:

(Ec 2-46) $$P_0 = \frac{1}{2}\rho A v_1^3$$

La relación entre la potencia mecánica extraída por el rotor (Ec 2-45) a esta de la corriente de aire imperturbada (Ec 2-46) se le llama coeficiente de potencia c_p

(Ec 2-47) $$c_p = \frac{P}{P_0} = \frac{\frac{1}{4}\rho A(v_1^2 - v_2^2)(v_1 + v_2)}{\frac{1}{2}\rho A v_1^3}$$

Después de algunas operaciones en (Ec 2-47), el coeficiente de potencia puede ser expresado como una función del ratio de velocidades v_2/v_1.

(Ec 2-48) $$c_p = \frac{P}{P_0} = \frac{1}{2}\left|1 - \left(\frac{v_2}{v_1}\right)^2\right|\left|1 + \left(\frac{v_2}{v_1}\right)\right|$$

El coeficiente de potencia, es decir la relación entre la potencia mecánica extraíble y la potencia contenida en la corriente de aire, por lo tanto ahora depende de la relación de la velocidad del aire antes y después del rotor. Si está interrelación se dibuja[30] se puede ver que el coeficiente de potencia tiene un máximo a un cierto ratio de velocidades (Figura 2.19)

[30] Una solución analítica naturalmente es también fácil de encontrar

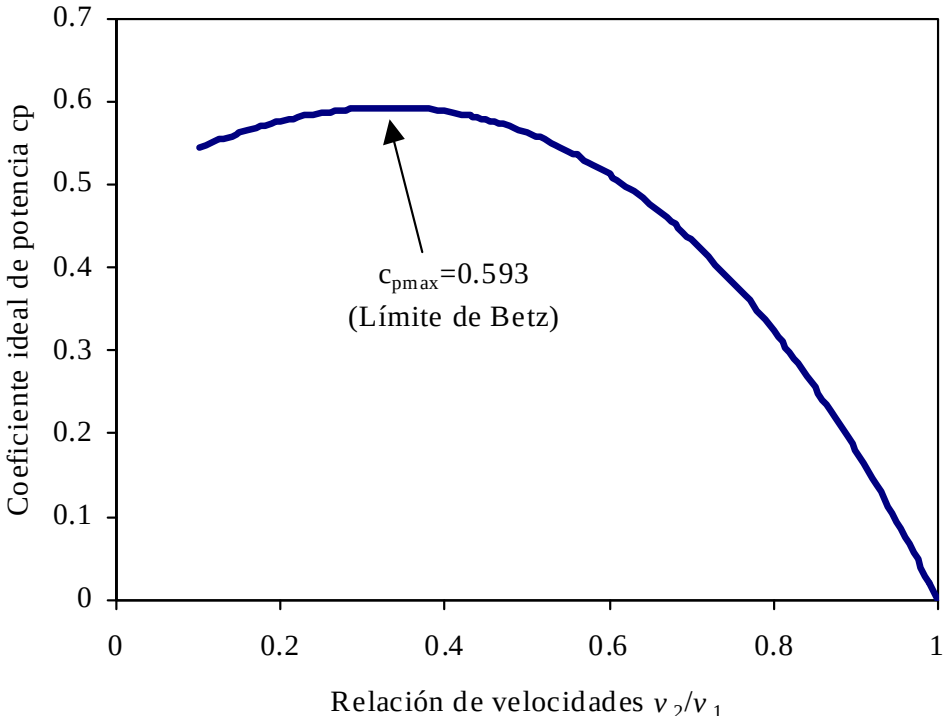

Figura 2.19:Coeficiente de potencia en función de la relación de velocidades después y antes del rotor

Con v_2/v_1=1/3 el coeficiente de potencia máximo ideal, denominado factor de Betz, es:

(Ec 2-49) $$c_p = \frac{16}{27} = 0.593$$

En la figura 2.20 se representa de nuevo la densidad de energía teórica mostrada en la figura 2.16 pero donde se puede observar la energía del viento no aprovechable como consecuencia de límites físicos (Ec 2-49).

En las máquina eólicas reales la existencia de un pequeño número de palas, las pérdidas por rozamiento y los efectos de borde hacen que la potencia máxima extraíble llegue a ser como mucho, entre el 60 o 70% del valor indicado por Betz (Ec 2-49). Así, la potencia real de salida se puede expresar por:

(Ec 2-50) $$P_r = c_p\left(\frac{1}{2}\rho A v^3\right)$$

En la que c_p depende de varios factores, entre los que se encuentra la velocidad del viento. Esta disminución de c_p respecto al límite de Betz dará lugar a que la potencia recuperable del viento sea inferior a la señala en la figura 2.19.

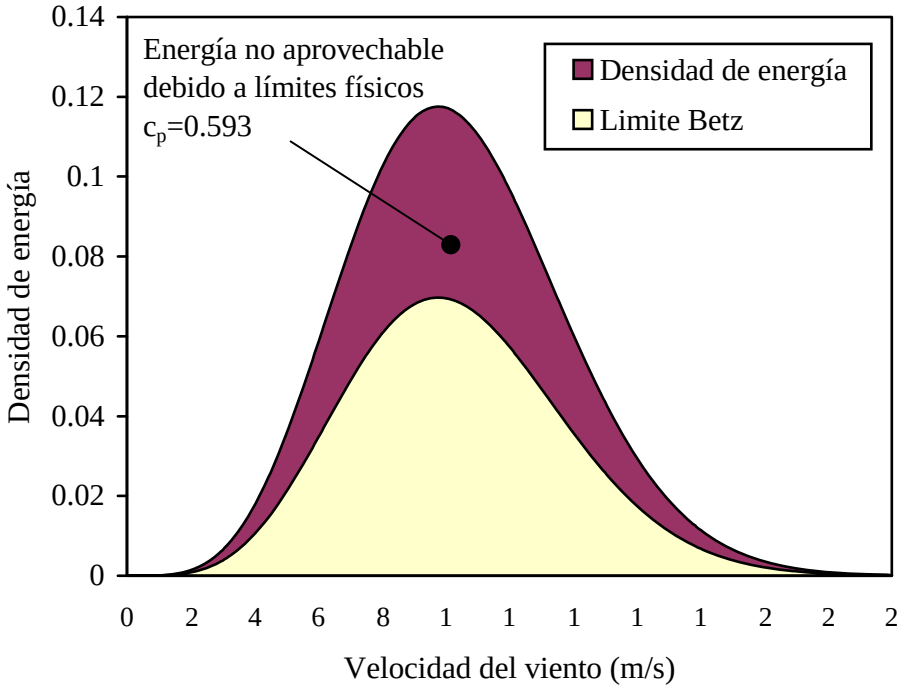

Figura 2.20:Densidad teórica de energía eólica y porcentaje de energía extraíble con una turbina eólica ideal

CAPÍTULO 3

Estimación de la producción de energía eléctrica de origen eólico. Los Parques Eólicos

INDICE

3. ESTIMACION DE LA PRODUCCION DE ENERGIA ELECTRICA DE ORIGEN EOLICO. LOS PARQUES EOLICOS 49

3.1 Introducción. 49

3.2 Sistemas de conversión de la energía eólica. Los Aerogeneradores 49

3.2.1 Características de funcionamiento de las turbinas eólicas. 60

3.3 Métodos de estimación de la energía eléctrica de origen eólico. 67

3.3.1 Método estático. 68

3.3.2 Método cuasidinámico. 72

3.3.3 Método dinámico. 73

3.4 Sistemas de explotación de la energía eólica. Los Parques Eólicos 74

3.4.1 Parques eólicos interconectados con la red eléctrica. 76

3.4.2 Parques eólicos en sistemas aislados 76

3.4.3 Parques eólicos con consumos asociados 77

3. ESTIMACION DE LA PRODUCCION DE ENERGIA ELECTRICA DE ORIGEN EOLICO. LOS PARQUES EOLICOS

3.1 Introducción.

La potencia producida por un aerogenerador depende del viento que sopla sobre el rotor1 de la máquina y de las características aerodinámicas, mecánicas, eléctricas, electrónicas, etc., de la misma [79,145].

Como señala Biswas *et al* (1995) [80], uno de los problemas en los proyectos de parques eólicos es obtener una estimación razonable de la energía generada, durante un periodo de tiempo, por una máquina eólica que se instale en un lugar determinado. En los estudio de viabilidad de este tipo de instalaciones es esencial obtener la estimación energética con antelación. Este cálculo es fundamental, entre otros aspectos, para analizar la integración de la instalación en la red eléctrica a la cual se conecte y para la toma de decisión en la ejecución del proyecto según su viabilidad económica.

En este capítulo de las tesis se presentan, en primer lugar, una serie de conceptos básicos sobre convertidores modernos de energía eólica en energía eléctrica (aerogeneradores) y, en segundo lugar, se analizan los métodos más frecuentemente empleados para estimar la potencia producida por un aerogenerador.

3.2 Sistemas de conversión de la energía eólica. Los Aerogeneradores

Los sistemas de conversión de la energía cinética contenida en una corriente de aire en energía eléctrica (aerogeneradores) han evolucionado considerablemente a lo largo de la historia [35, 81]. En general, han sido máquinas rotativas de muy diverso tamaño en las que el rotor, o sistema de captación, está unido a un eje.

Estos aerogeneradores pueden clasificarse según sea la posición de su eje en vertical u horizontal.

[1] Parte de la máquina que transforma la energía del viento en energía mecánica

Figura 3.1:Aerogenerador de Eje Vertical

Los aerogeneradores de eje vertical de mayor desarrollo han sido los denominados Darreius (Figura 3.1). Estas turbinas, a pesar de presentar ciertas ventajas de carácter estructural, como son el no necesitar mecanismo de orientación y la facilidad de instalar el generador eléctrico en tierra, muestran desventajas considerables, entre las que cabe destacar su menor producción energética, a igual potencia instalada, respecto a un aerogenerador de eje horizontal [82].

Los aerogeneradores de eje horizontal (Figura 3.2) son, con diferencia, los tipos de sistemas de captación eólica más desarrollados y utilizados en la producción energética, empleándose desde capacidades del orden de vatios a grandes aerogeneradores de potencia del orden de varios MWs. Debido a ello, serán el tipo de máquinas eólicas utilizadas en esta tesis y, por tanto, las que básicamente se comentarán en los siguientes apartados.

Figura 3.2:Aerogenerador de eje horizontal

En general, los aerogeneradores de eje horizontal constan de un subsistema que capta la energía cinética del viento y la transforma en energía mecánica de rotación y de un subsistema de conversión de la energía mecánica en eléctrica, compuesto de un tren de potencia y del generador eléctrico. El conjunto se completa con un bastidor y una carcasa, que alberga los distintos mecanismos, así como una torre que sustenta todo el sistema y los correspondientes subsistemas de control, orientación e infraestructura eléctrica.

El diagrama de bloques de la figura 3.3, que muestra la conexión entre los componentes más importantes y las etapas de conversión de energía asociadas, puede servir como base de las breves descripciones que de los mismos se realizarán seguidamente. El diagrama también da una idea de cómo el funcionamiento puede ser influenciado por los procesos de control y supervisión.

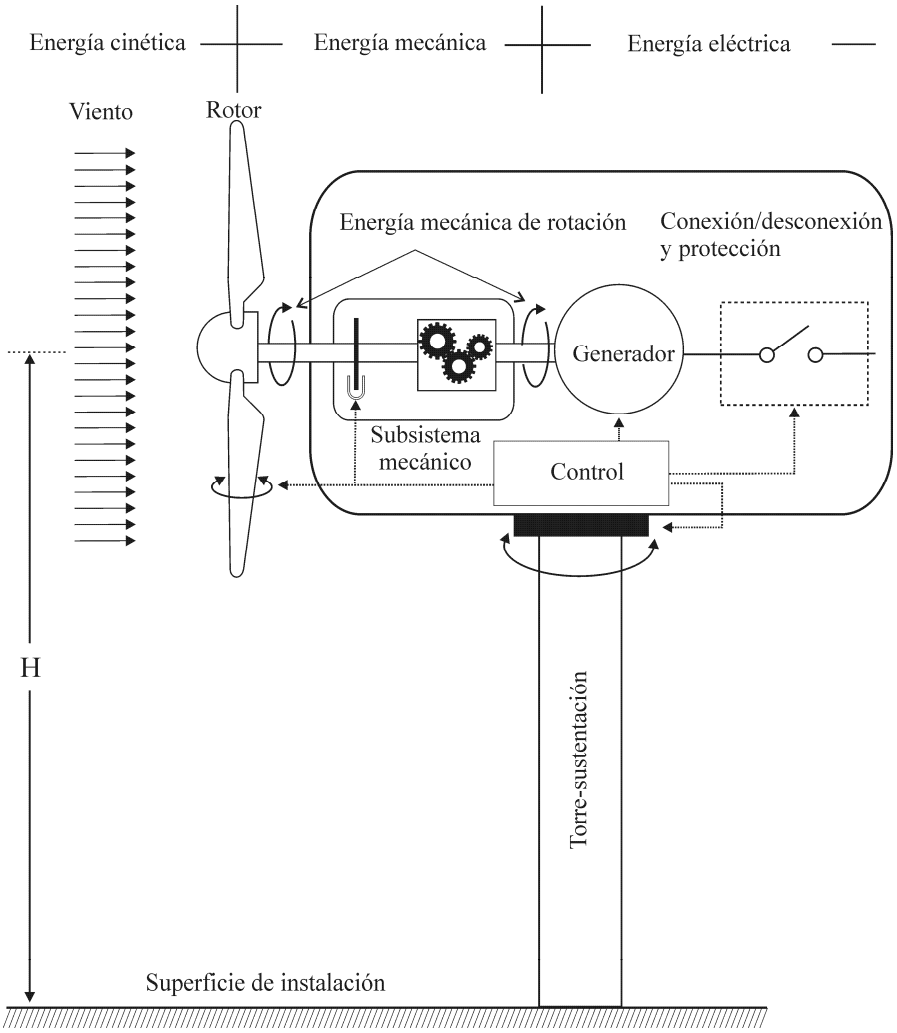

Figura 3.3:Transferencia de potencia en un convertidor de energía eólica

- **El rotor o subsistema de captación de energía** es la parte del aerogenerador que transforma la energía cinética del viento en energía mecánica de rotación. El rotor está compuesto por las palas y el buje. El rotor es a menudo considerado como el subsistema más importante tanto desde el punto de vista del funcionamiento como del de costos [83]. Los componentes más importantes del rotor son las palas. Ellas son los dispositivos que convierten la fuerza del viento en el par necesario para generar potencia útil La forma básica y dimensiones de las palas vienen dadas inicialmente por el diseño global de la turbina y por consideraciones aerodinámicas [84]. Las palas habitualmente se fabrican en resina de poliéster reforzadas con fibra de vidrio, disponiendo internamente de un larguero resistente,

sobre el que se incorporan los perfiles aerodinámicos variables en forma, tamaño y orientación a lo largo de la pala.

El buje de la turbina eólica es el componente que conecta las palas al árbol principal de transmisión y finalmente al resto del tren de potencia. Hay tres tipos básicos de bujes que se aplican en las turbinas modernas de eje horizontal: Bujes rígidos, bujes balanceantes (teetering), y bujes para palas articuladas. Los bujes rígidos, como su nombre indica, tiene todas las partes unidas rígidamente al árbol principal de transmisión. Son los diseños más comunes y son casi universales en los aerogeneradores de tres palas. Los bujes basculantes permiten un movimiento relativo entre las partes que se conectan a las palas y que se conectan al árbol principal. Los bujes balanceantes son usados comúnmente en turbinas con dos y una pala. Los cubos con palas articuladas permiten movimientos independientes de aleteo de cada pala con respecto al plano de rotación. Estos bujes son usados solo en pocos diseños de turbinas y son de alguna forma una mezcla entre los bujes rígidos y los bujes balanceantes. Son básicamente bujes rígidos con “bisagras” para las palas [6,83,84].

Los rotores se clasifican en:

- Rotores lentos y rápidos. Dicha clasificación viene dada por relación específica de velocidades λ_o [33], definida como el cociente entre la velocidad lineal en la punta de la pala del rotor y la velocidad del viento. Los rotores utilizados para la producción de electricidad son rápidos (λ_o.>3). Debido a su gran velocidad de rotación, los rotores rápidos llevan pocas palas: 2, 3, normalmente, adquiriendo por ello diversas ventajas respecto de los lentos o multipalas [33]
- Rotores de paso fijo y variable. Según que el ángulo de calaje de las palas sea constante o permita un movimiento de giro sobre su propio eje (Figura 3.3). La posibilidad del cambio de paso de pala permite una mayor producción energética causada por una mejor adaptación aerodinámica de la pala al viento incidente. Se controla de este modo la potencia obtenida.
- Rotores de velocidad constante y velocidad variable. Muchos aerogeneradores se diseñan para que la velocidad de giro del rotor sea constante (fijada en base a los 50 Hz de la red eléctrica a la que se conectan), pero también existen aerogeneradores de velocidad de giro variable, lo que les permite una mayor adaptación a la velocidad del viento.

- Rotor a barlovento y rotor a sotavento. La mayoría de los aerogeneradores actuales disponen de rotor enfrentado a la dirección del viento (barlovento), pero también existen aerogeneradores con su rotor situado a sotavento. Con esta última disposición se consiguen ventajas desde el punto de vista de la orientación, sin embargo, se presenta un problema adicional conocido como efecto sombra, el cual origina oscilaciones en las palas, además de ciertos fenómenos acústicos de baja frecuencia.

- **El tren de potencia mecánico.** Un tren de potencia completo de un aerogenerador está compuesto por todas las partes en rotación de la turbina. Estas incluyen un árbol de baja velocidad (en el lado del rotor), acoplamientos, freno, caja multiplicadora de engranajes, y un árbol de alta velocidad (en el lado del generador).

  Toda turbina tiene un árbol principal, algunas veces denominado árbol de baja velocidad o árbol del rotor. El árbol principal transfiere el par torsor desde el rotor al resto del tren de potencia.

  Los acoplamientos tienen como función conectar los árboles. Hay dos lugares en particular de las turbinas eólicas donde es probable que se instalen grandes acoplamientos: Entre el árbol principal y la caja de engranajes, y entre el árbol de salida de la caja de engranajes y el generador.

  El multiplicador tiene como función adaptar la baja velocidad de rotación del eje del rotor a las mayores velocidades de operación del generador eléctrico. Existen dos tipos básicos de cajas de engranajes usadas en los aerogeneradores: Cajas de engranajes de árboles paralelos y cajas de engranajes planetarios. En algunos diseños no se considera el uso del multiplicador, siendo sustituida su función por elementos de carácter eléctrico o electrónico.

  Casi todos los aerogeneradores emplean frenos mecánicos en alguna parte del tren de potencia. Estos frenos son incluidos normalmente además de la existencia de frenos aerodinámicos. En la mayoría de los casos, el freno mecánico es capaz de parar la turbina. En otros casos, el freno mecánico se usa sólo para impedir que el rotor gire cuando la turbina no esta funcionando. El freno de uso más común en los aerogeneradores es el freno de disco y suele estar ubicado bien en el lado de baja velocidad de la caja de engranajes o en el lado de alta velocidad de la misma.

- **El sistema eléctrico.** El sistema eléctrico de un aerogenerador incluye todos los componentes para convertir la energía mecánica en energía eléctrica, si bien el generador constituye el foco de dicho sistema. Los generadores que actualmente utilizan en las

aeroturbinas suelen ser alternadores, que a su vez puede ser de inducción (asíncronos) o de excitación (síncronos). Cada uno de estos tipos de generadores tiene diferentes características, tanto en los requerimientos de entrada como en las particularidades de la corriente de salida.

- Un generador asíncrono produce energía eléctrica, en el estator, cuando la velocidad de giro de su rotor, impulsado por el eje de alta, es superior a la velocidad de giro del campo magnético de excitación creado por el estator. El generador asíncrono necesita tomar energía de la red para crear el campo de excitación del estator. Esta energía al alimentar una bobina consumirá corriente desfasada de la tensión (energía reactiva), con lo que la línea eléctrica de distribución a la que se encuentra conectada la instalación eólica, desestabiliza su cos φ.
- El generador síncrono está formado por un rotor compuesto por electroimanes generadores del campo magnético y de un estator en cuyo devanado se producirá la corriente alterna inducida por el campo magnético variable creado por el rotor. Los electroimanes del rotor del generador son alimentados con corriente continua, rectificando parte de la propia electricidad generada.

El sistema eléctrico de un aerogenerador de eje horizontal está condicionado por las características de operación del rotor, es decir, si su rotor opera a revoluciones constantes o revoluciones variables, y por el sistema de utilización, ya sea conexión directa a la red o funcionamiento aislado, por lo que se pueden presentar diversas posibilidades [85, 86].
La mayoría de las actuales turbinas eólicas están equipadas todavía con generadores que funcionan a velocidad constante y que operan acopladas directamente a la red. En la mayoría de los casos, incluso hoy día, las consideraciones de costos prefieren este concepto a pesar de las considerables desventajas para la operación aerodinámica del rotor y de las superiores cargas dinámicas en los componentes del tren de potencia. Con el progreso en la tecnología de los inversores el acoplamiento directo a la red con generadores operando a velocidad variable ha comenzado a incrementar el atractivo económico. Las posibilidades más destacadas, dentro de un cierto abanico [85], son:

- Generadores síncronos operando a velocidad de giro constante y conectados directamente a la red.

- Generadores asíncronos operando a velocidad de giro constante y conectados directamente a la red.
- Generadores síncronos con convertidores AC/DC/AC operando a velocidad de giro variable conectados a la red.
- Generadores asíncronos con control de deslizamiento.

Desde el punto de vista de la ingeniería eléctrica, los aerogeneradores son plantas de generación de potencia, parecidas a las plantas hidroeléctricas o las plantas de generación diesel. Sus sistemas eléctricos son similares y deben reunir los requisitos de los sistemas conectados a la red pública. Estos requisitos conciernen principalmente a los sistemas de seguridad y calidad de la potencia. Los generadores eléctricos realmente representan la pieza central del sistema eléctrico, pero el sistema completo comprende numerosas piezas de equipos eléctricos y electrónicos (contactores, instrumentos de medida, elementos de transformación, etc)

- **Sistema de orientación**. El cambio de dirección del viento incidente, hace necesaria la orientación del rotor situándole perpendicularmente a dicha dirección. Existen dos clases de sistemas de orientación: orientación activa y pasiva. Las turbinas con orientación activa normalmente disponen de rotor a barlovento. Para realizar la orientación se utiliza la información obtenida a partir de los datos de dirección de viento y posición de la máquina. La información conseguida es transmitida a un motorreductor de orientación. El motorreductor que esta embridado sobre el bastidor actúa sobre una corona de grandes dimensiones, uno de sus aros fijos al bastidor y el otro a la torre. La actuación del motorreductor sobre la corona produce el giro del bastidor. Para inmovilizar el giro se suele utilizar un freno. Los sistemas de orientación denominados pasivos cuentan con elementos mecánicos (veletas, rotores laterales auxiliares) o disponen de rotor a sotavento, que debido al efecto de conicidad del mismo genera unas fuerzas aerodinámicas que tienden a autoorientar la turbina en la dirección del viento [46, 84].

- **Control**. Para generar potencia con éxito a partir de los componentes de las turbinas, éstas necesitan de un sistema de control que enlace la operación de todos los subsistemas. La determinación del control óptimo vendrá condicionado por factores como la protección y seguridad del sistema, la optimización de la energía producida o el incremento de la vida útil de los equipos. Por otra parte el sistema de control suele llevar incorporado dispositivos de

comunicación con el que recibir y enviar información al operador del conjunto de la instalación.

Los sistemas de control constan de sensores que informan sobre el estado de la máquina y del viento incidente (velocidad, dirección, etc), un sistema central que compara dicha información con la programada como óptima, y unos actuadores que, controlados por el sistema central, modifican el comportamiento de la turbina, acercándolo al óptimo.

Aunque los detalles de los sistemas de control varían significativamente de una turbina a otra [83, 85, 86], todos los aerogeneradores tienen un propósito común: convertir la energía cinética del viento en energía eléctrica. Este propósito común define elementos comunes que se necesitan considerar en el diseño de cualquier sistema de control.

Los elementos más importantes de control hacen referencia al control de potencia y régimen de giro así como de orientación (Figura 3.3).

Los problemas fundamentales del control de potencia en una turbina quedan particularmente patentes si la tarea de control se compara con la de una planta convencional de vapor. En una planta convencional existen tres métodos de control disponibles para controlar el sistema global (el suministro de fuel, la alimentación de vapor a la turbina, la excitación del generador eléctrico). Si se observa una turbina eólica, se comprende inmediatamente que el primer control, la dosificación de la energía primaria de entrada, no existe. Para regular la velocidad de rotación y la potencia generadas las turbinas eólicas pueden contar con la modificación de dos parámetros: El ángulo de paso de las palas[2] y el par del generador eléctrico.

La turbina eólica debe hacer frente a una variación aleatoria de la fuente de energía primaria, es decir, el viento. La energía primaria del rotor de la turbina puede ser controlada únicamente con el cambio del ángulo de paso de las palas. Las fluctuaciones extremadamente breves (turbulencias del viento y rachas) de menos de unos pocos segundos no pueden ser respondidas con el control del ángulo de paso de las palas. La inercia de las palas del rotor y de los elementos actuantes no lo permiten. Como el sistema de control no puede responder dentro de estos periodos de tiempo, las cargas resultantes deben ser soportadas por la turbina y las fluctuaciones de potencia deben ser aceptadas. Los cambios en la velocidad del viento dentro del rango de varios segundos pueden ser respondidos por el sistema de control. Esta es la tarea real del sistema de control. Con la ayuda de las dos variables de control mencionadas,

[2] Es posible controlar la potencia mediante rotores provistos de palas diseñadas para regular la captación de energía por pérdidas aerodinámicas, pero que son poco precisos. En el apartado 3.3 se puede observar su efecto en la curva de potencia-velocidad característica de un aerogenerador conectado a al red.

el sistema de control puede garantizar puntos de operación estables. El control de velocidad es indispensable cuando la velocidad no es mantenida por la frecuencia de la red. Este es siempre el caso del funcionamiento en régimen aislado. Pero también en turbinas conectadas a la red, el control de velocidad es necesario durante el arranque o cuando se cierra y en generadores con conexión no directa a la red. El control de potencia es un imperativo para proteger las turbinas de sobrecarga, o porque la demanda de potencia de los consumidores lo requiere.

La estructura de control de una turbina debe ser diseñada para ajustar las características del sistema mecánico-eléctrico. Aquí pueden distinguirse cinco subsistemas: Características mecánicas del sistema de cambio de paso de las palas, Aeroelasticidad de las palas, par aerodinámico del rotor, dinámica del tren de potencia mecánico y características eléctricas del generador.

En operación en sistemas aislados o en operación en una red eléctrica frágil, las características de la red y a veces del consumidor deben ser consideradas adicionalmente.

Desde el punto de vista del control, el funcionamiento de una turbina a una frecuencia fijada por la red representa el caso más simple. Con respecto a la turbina eólica, las redes públicas grandes pueden siempre ser consideradas que tienen una frecuencia constante. Los cambios de carga causados por la turbina alimentando a la red, incluso en instalaciones de megavatios, son demasiado pequeñas como para ejercer una influencia considerable en la frecuencia, comparada con la carga total de la red.

Desde el punto de vista del control, el funcionamiento en aislado de una turbina eólica puede ser definido inversamente al de la operación en conexión a una red: No se dispone de la posibilidad de que la velocidad del generador se guíe por una frecuencia fija de red y la potencia instantánea de salida de la turbina eólica ya no es arbitraria, pero debe ser controlada en relación a la demanda de potencia instantánea del consumidor. En redes débiles la turbina deberá mantener la frecuencia de la red y adaptar su potencia de salida a ciertas condiciones de carga de la red.

El control de la velocidad de giro en sistema aislados mediante el control del ángulo de paso de las palas sólo es posible si la potencia suministrada por el viento es mayor que la potencia tomada por el consumidor. En los sistemas aislados deben diferenciarse dos áreas de operación:

a) Si la energía suministrada por el viento es mayor que la potencia demandada por el consumidor (área de carga completa), la velocidad y potencia de salida pueden ser controladas por el cambio del ángulo de paso de las palas.

b) Si la potencia del viento es más pequeña que la potencia demandada por el consumidor (operación a carga parcial), la turbina debe entonces asegurar que la potencia tomada por el consumidor se reduce en consecuencia. Esto tiene que ser gestionado por un gestor de cargas que decide que consumidores son desconectados o conectados del suministro.

En el caso de turbinas que carezcan de rotor de paso variable las posibilidades de control se encuentran altamente restringidas. No obstante, si se elige un sistema de generación adecuado pueden reunirse los requisitos de operación en red sin gran dificultad. En sistemas aislados de la red, sin embargo, es una tarea mucho más complicada, pero posible no obstante. Cuando la potencia capturada por el rotor no puede ser controlada adecuadamente, el control de la velocidad o frecuencia puede sólo ser conseguido cambiando la carga del generador [87,88]. El circuito de cargas del consumidor, no es generalmente suficientemente rápido para el control de velocidad, entonces son necesarias cargas adicionales llamada cargas de volcado. Con su ayuda la carga puede ser rápidamente adaptada a las fluctuaciones del régimen de vientos.
El control de la orientación del rotor de la turbina está caracterizado por un conflicto de intereses. Por un lado, la desviación de la orientación del rotor respecto a la dirección del viento se supone que debe ser tan pequeña como sea posible para evitar perdidas de potencia. Por otro lado, el sistema de orientación no debe ser demasiado sensible, para evitar permanentes pequeños movimientos de orientación que reducen la diva de los componentes mecánicos. Los modernos sistemas de orientación se nutren de la información que, sobre el valor medio de la dirección del viento, proporciona una veleta situada en la góndola o en zonas estáticas del rotor.

- **Góndola.** Los elementos anteriormente descritos van instalados sobre una estructura portante que constituye el bastidor. El bastidor descansa sobre un rodamiento de grandes dimensiones a través del cual está acoplado a la torre, estando todo ello resguardado de las inclemencias mediante una carcasa o estructura de cierre y protección. Normalmente al conjunto de bastidor y carcasa se le denomina góndola.

- **La torre y cimentación**. La mayoría de las torres de las turbinas se construyen de acero, aunque también se fabrican de hormigón [46]. La función de la torre es elevar las partes principales de la turbina. En las turbinas de eje horizontal la torre debe ser al menos tan alta que permita mantener las puntas de las palas alejadas del suelo al girar. En la práctica,

como los vientos incrementan su intensidad y son menos turbulentos según se alejan del suelo, las torres tiende a ser bastante elevadas. La elección de la altura de la torre depende de un compromiso entre el coste de la misma y el incremento de energía que se consigue. Las opciones más comunes de torres son tubulares, estructuras tipo tuberías o celosías (normalmente atornilladas). Los criterios de elección suelen estar condicionados por su frecuencias naturales de vibración, modos de instalación y estética [83].

Las torres van cimentadas en el terreno mediante pilotes o zapatas de hormigón armado cuyo tamaño dependerá de las características del terreno y las solicitaciones mecánicas que deba soportar. En su base superior llevan las bridas de anclaje, incorporándose además los tubos para el paso de los cables. Las torres de turbinas de alta potencia se fijan a las cimentaciones mediante pernos de alta resistencia.

3.2.1 Características de funcionamiento de las turbinas eólicas.

La determinación del funcionamiento de una turbina eólica bajo un cierto régimen de vientos que permita estimar su potencia de salida y su producción energética requiere involucrar las características de operación de los componentes que la integran, es decir, las características del rotor, del tren de potencia, del sistema eléctrico y del sistema de control.

El punto de comienzo para determinar el funcionamiento de una turbina eólica son las características aerodinámicas del rotor. Generalmente, estas características se suelen expresar por medio de curvas de operación adimensionales. Los parámetros, que se representan en función de la relación de velocidades en la punta de la pala λ.[3] (Ec 3-1) y del ángulo de paso de la pala ϑ[4], suelen ser los coeficientes de potencia[5], de par torsor[6] y de empuje axial[7]; [33,46,84].

(Ec 3-1) $$\lambda = \frac{U}{V} = \frac{\omega R}{\mathrm{V}} = \frac{\text{Velocidad punta pala}}{\text{Velocidad del viento}}$$

[3] Relación entre la velocidad lineal del rotor en la punta de la pala y la velocidad del viento. Por tanto, función de la velocidad de rotación ω, del radio del rotor *R* y de la velocidad del viento *V,*

[4] Ángulo formado entre el plano del rotación del rotor y la cuerda de la pala

[5] Relacionado con la con la cantidad de energía capturada por el rotor de la eólica

[6] Relacionado con el par mecánico que es capaz de desarrollar el rotor de la eólica

[7] Relacionado con el empuje axial que el viento realiza según el eje del rotor y que influye en el diseño estructural de la torre de la eólica.

En la figura 3.4 se representa el coeficiente de potencia C_p (Ec 3-2)[8] del rotor de una determinada turbina en función de λ y ϑ[9].

(Ec 3-2) $$C_p = \frac{P}{1/2\rho V^3 A} = \frac{\text{Potencia del rotor}}{\text{potencia del viento}}$$

donde ρ es la densidad del aire, V la velocidad del viento y A el área barrida por el rotor de la turbina eólica. Este coeficiente, que representa la cantidad de energía eólica transformada en energía mecánica en el rotor de la eólica, tiene un valor máximo ideal de 0.593, al cual se le denomina *factor de Betz* [33,46,85] ya explicado en el capítulo 2 del presente trabajo.

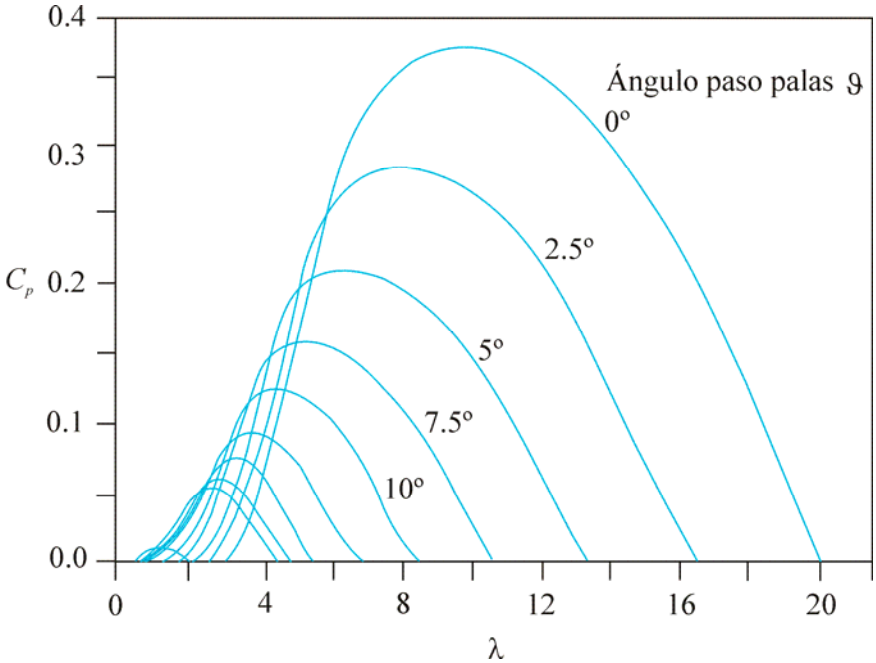

Figura 3.4:Coeficiente de potencia de un rotor de una turbina eólica

Por tanto, de la teoría aerodinámica de las palas [6,33,46,83,84], la potencia mecánica del rotor vendrá dada por (Ec 3-3)

[8] Las curvas C_p -λ obtenidas a través de medidas experimentales o de cálculo pueden aproximadas por funciones no lineales.

[9] El ángulo de paso de una pala varía a lo largo de su longitud (Lysen, 1982), por tanto, el ángulo que se suele representar en estas gráficas es el correspondiente a una distancia del eje del rotor entre el 70% y 75º, aproximadamente, del radio del mismo (Koeppl, 1982).

(Ec 3-3) $$P = \frac{\rho}{2} C_p(\lambda, \vartheta) A V^3$$

A partir de las curvas de la figura 3.4 y teniendo en cuenta la relación (Ec 3-1), es posible expresar la potencia mecánica del rotor (Ec 3-3) como una función de la velocidad de giro del mismo ω, del ángulo de paso ϑ y de la velocidad del viento *V*. En la figura 3.5 se ha representado la variación de *P* en función, exclusivamente, de ω y *V*.

El método usado para predecir la curva de potencia del aerogenerador se basa en acoplar la potencia mecánica generada por el rotor de la turbina eólica (Figura 3.5), con la potencia del generador eléctrico, trazada ésta en función de la velocidad de rotación del rotor.

El problema es complejo debido a que la curva potencia velocidad de rotación depende del tipo de generador, del factor de potencia y la magnitud de la carga, del campo de corriente, y de que la velocidad de rotación de la máquina sea mantenida constante por la red o que se permita su variación. Además existe una complicación añadida ya que muchos generadores se diseñan para operar a una única óptima velocidad de rotación, y a menudo es difícil encontrar sus características a velocidades más bajas.

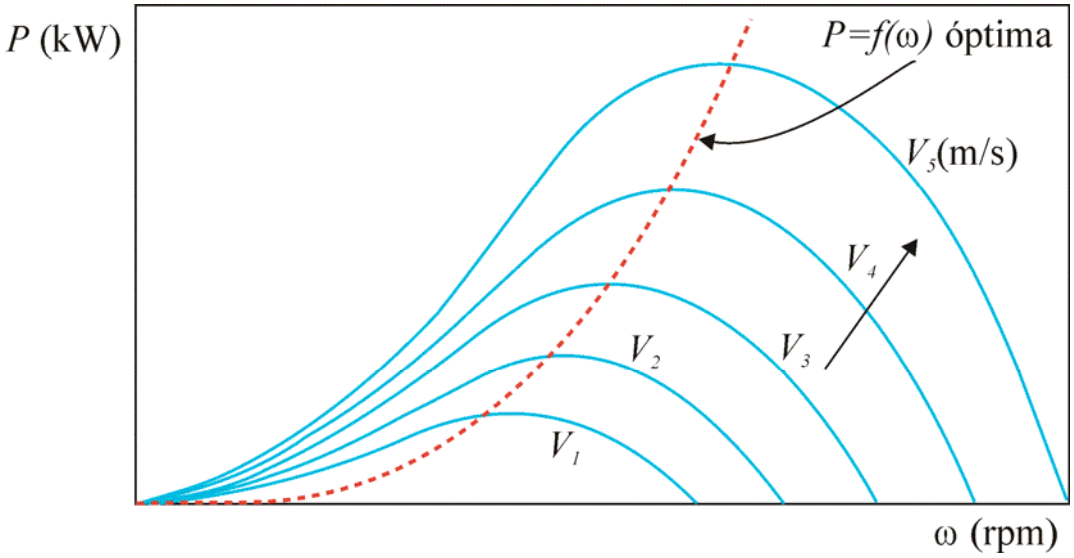

Figura 3.5:Potencia del rotor de una turbina en función de la velocidad de giro

Si se asume que se trata de un generador que suministra energía a una red eléctrica de frecuencia constante que comprende otras unidades de producción y que se dispone de su curva de potencia en función de la velocidad de rotación y de las curvas de potencia del rotor

de la máquina eólica (Figura 3.5), la única variable es la relación de transmisión de la caja de engranajes (*k*), necesaria para el correcto acoplamiento de la velocidad de giro del rotor (ω_g/k) y la velocidad de giro constante[10] del generador (ω_g).

Una vez que la relación ha sido fijada (Figura 3.6), las ordenadas de los puntos de intersección de la recta representativa del generador con las características potencia-velocidad de la turbina eólica, corresponden a los diversos valores de la potencia aportada por la turbina eólica al generador para los diferentes valores de la velocidad del viento.

En la práctica, se adopta como relación de transmisión un valor de *k* tal que la vertical de abscisa (ω_g/k), corte las curvas características de potencia velocidad de la eólica relativas a los vientos aprovechables más próximos a sus valores máximos.

El conocimiento del rendimiento global del sistema (rodamientos, multiplicador, sistema eléctrico) y de la intensidad de la excitación permiten obtener para cada punto de la recta vertical o inclinada[11] (ω_g/k) la potencia proporcionada por el generador a la red en función d la velocidad del viento.

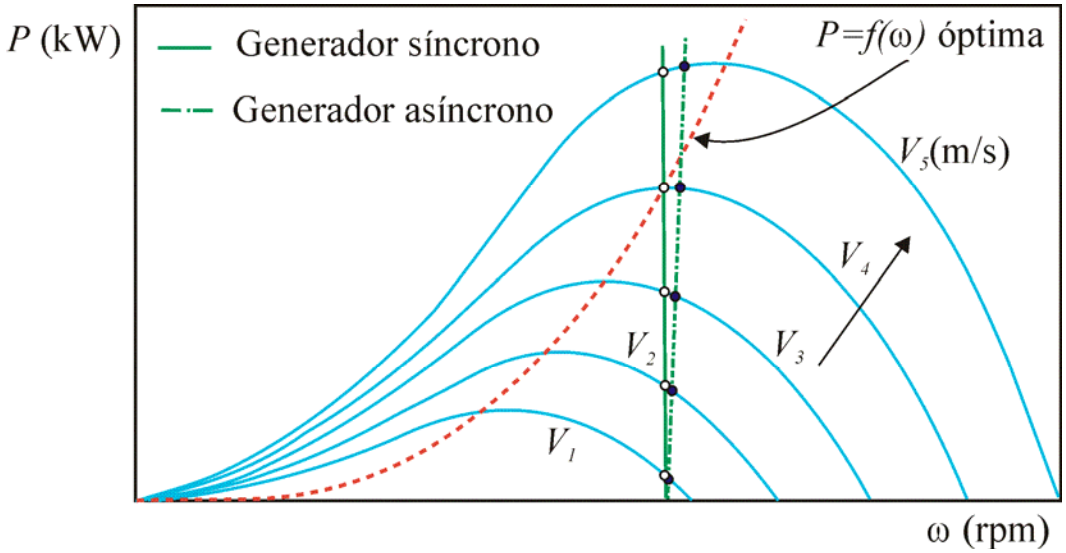

Figura 3.6:Rotor acoplado a un generador de velocidad constante conectado a la red eléctrica

[10] Lo mismo sucede con la velocidad de giro del rotor de la eólica en la medida que su relación de transmisión permanece invariable.

[11] Vertical continua para el caso de un generador síncrono e inclinada para el generador asíncrono, ya que la velocidad de rotación de este último aumenta ligeramente con la carga (Le Gouriérès, 1983; Lysen, 1983; Heier, 1998)

En la figura 3.7 se muestra la conexión de las características de un rotor con las de un generador síncrono operando a velocidad variable con convertidores AC/DC/AC. Como en el caso de la figura 3.6, la intersección de la curva representativa del generador con las características potencia-velocidad de la eólica, corresponden a los diversos valores de la potencia aportada por la eólica al generador para los diferentes valores de la velocidad del viento. Sin embargo, en este caso, puede observarse que puede lograrse un mejor aprovechamiento de la energía del viento.

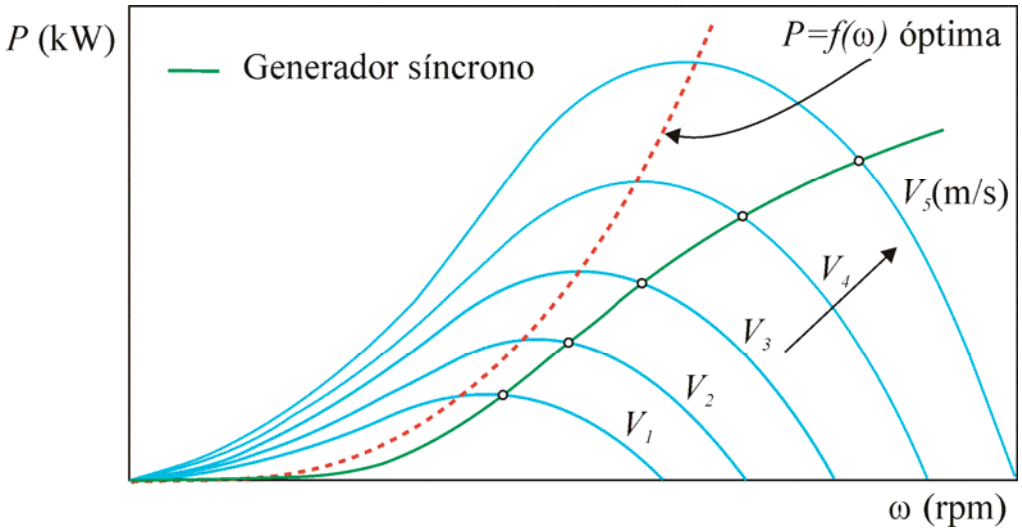

Figura 3.7:Rotor acoplado a un generador síncrono de velocidad variable con convertidores AC/DC/AC

Como puede deducirse de las figuras 3.6 y 3.7, las posibilidades de acoplamiento son muy variadas [86], ya que la estrategia de control[12] juega también un papel fundamental.

En la figura 3.8 se muestra la obtención de la curva que representa la potencia eléctrica generada por la turbina eólica en función de la velocidad del viento a la altura del eje del rotor de la misma. Como puede observarse, las condiciones de operación fuerzan la existencia de una velocidad mínima necesaria para que la eólica comience a generar; a dicha velocidad se le denomina velocidad de arranque V_a. Asimismo, puede observarse como a partir de la velocidad V_a la potencia generada por la turbina se incrementa con la velocidad del viento. Dicho incremento se limita, mediante procedimientos de control, a partir de una velocidad V_n,

denominada velocidad nominal; de tal manera que para velocidades superiores a V_n la potencia tienda a mantenerse constante. A dicha potencia se la denomina potencia nominal P_n. Por último, para evitar la rotura de la turbina cuando la velocidad del viento alcanza magnitudes altas, el sistema de control detiene el funcionamiento de la turbina eólica. La velocidad a la cual se produce la detención del funcionamiento de la turbina se la denomina velocidad de parada V_p.

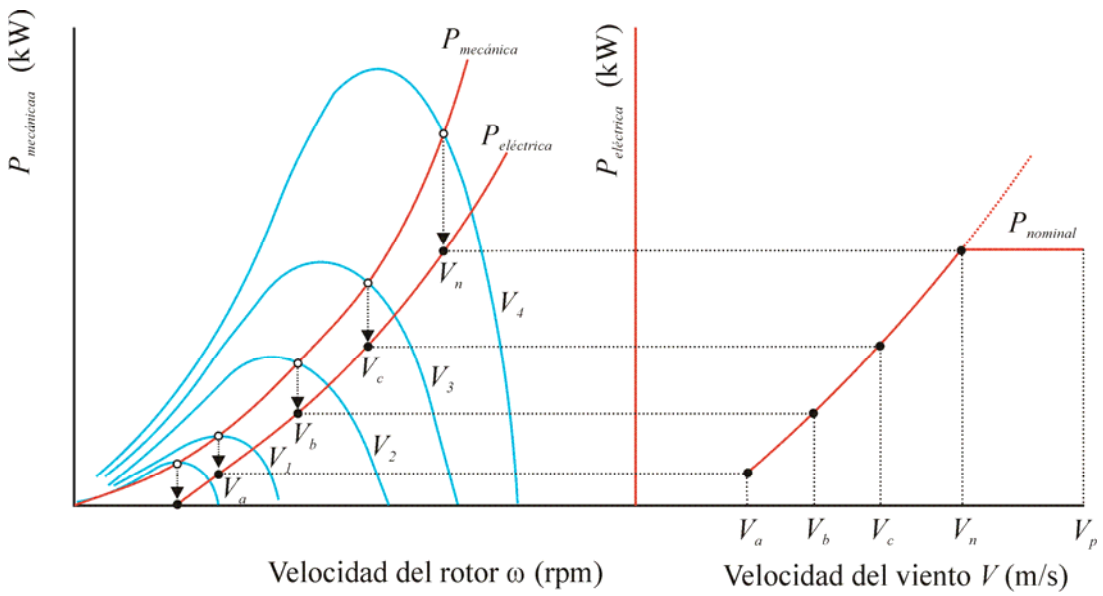

Figura 3.8:Obtención de la curva potencia-velocidad de una turbina eólica

En la práctica, la relación potencia-velocidad característica del funcionamiento de una aerogenerador se obtiene experimentalmente mediante ensayos normalizados [45]. De dichos ensayos se desprende que la mencionada relación presenta una cierta dispersión, como se muestra en la figura 3.9.

Mediante el procedimiento explicitado en las normas de ensayo [45] a dicha dispersión se le ajusta una curva que representa la curva característica potencia –velocidad del aerogenerador, para una determinada densidad del aire, y que se incluye en los catálogos técnicos de los fabricantes. Esta curva característica relaciona la potencia generada por la turbina con la velocidad del viento a la altura del eje del rotor de la misma bajo condiciones de flujo

[12] El uso o no del control del ángulo de paso. Uso del control del ángulo de paso en todo el rango de

estacionario.

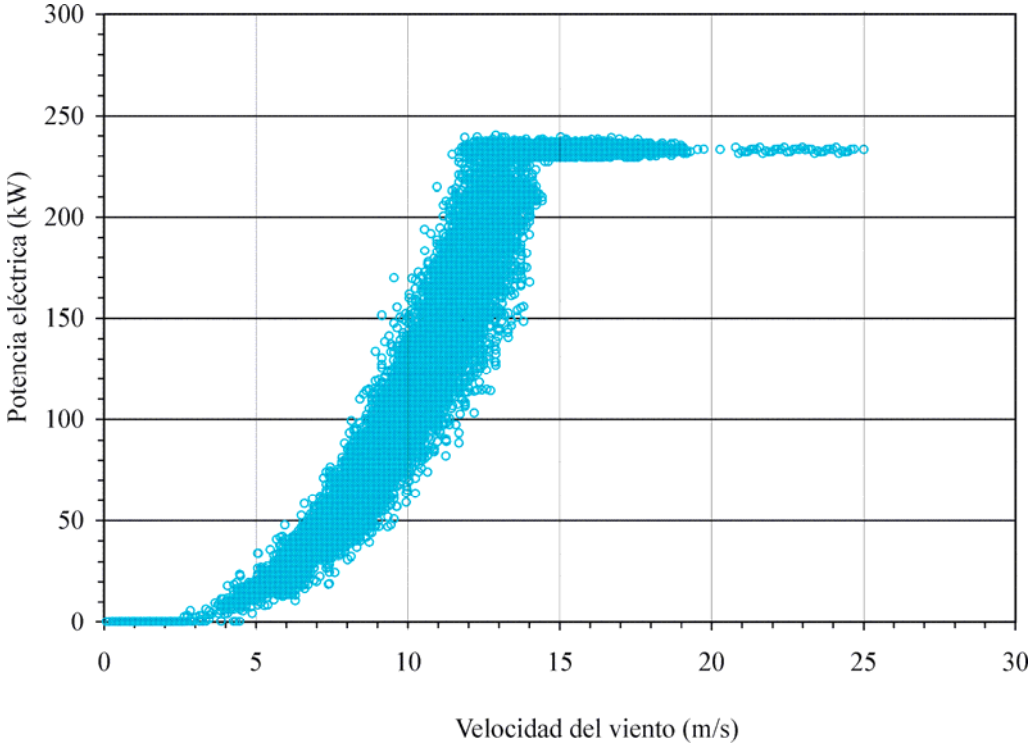

Figura 3.9:Curva de potencia experimental de un aerogenerador

En la figura 3.10 se muestran dos curvas potencia-velocidad normalizadas típicas de aerogeneradores con rotores con control de ángulo de paso y de aerogeneradores de paso fijo (stall)[13]. En este último caso el perfil de la pala ha sido diseñado aerodinámicamente para que a determinada velocidad de viento el flujo aerodinámico se separe de la superficie de la pala y se produzca una disminución de la potencia capturada del viento (33,84,85,89].

velocidades o en rangos parciales, etc.

[13] En los últimos años ha aparecido un sistema de control híbrido, mezcla entre control de ángulo de paso y stall, denominado “stall activo”.

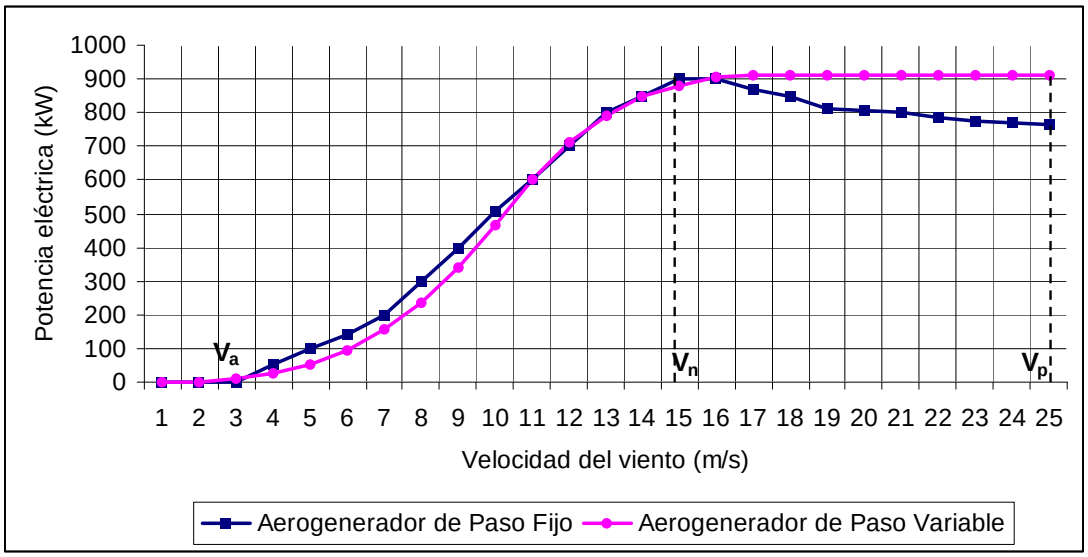

Figura 3.10:Curvas de potencia normalizadas de aerogeneradores comerciales

Como puede observarse en la figura 3.10, la máquina no genera potencia hasta que la velocidad del viento ha alcanzado un valor crítico "velocidad de arranque" v_a. Cuando la velocidad del viento continúa incrementándose, la potencia de salida también se incrementa hasta la "velocidad nominal" v_n, en la que la máquina produce su salida nominal P_n. Para velocidades del viento mayores que vn la salida se controla para mantenerla constante hasta alcanzar "la velocidad de parada" v_p, a la cual la máquina deja de generar por razones de seguridad mecánica o eléctrica.

3.3 Métodos de estimación de la energía eléctrica de origen eólico.

Dos son las características fundamentales a la hora de estimar la energía eléctrica generada por un aerogenerador en un emplazamiento determinado: El comportamiento del viento en la zona en cuestión (análisis del recurso eólico) y la curva de funcionamiento (P-V) (Figura3.10) del aerogenerador. A partir de dicha información se puede estimar la energía eléctrica obtenible mediante tres procedimientos diferentes:

- Método Estático
- Método Cuasidinámico
- Método Dinámico

3.3.1 Método estático.

En este método se acopla (Figura 3.11) la ley de densidad de probabilidad del viento de un determinado periodo, *f*(*v*), con la curva característica potencia-velocidad, *P*(*v*), de un aerogenerador para obtener la curva de probabilidad de potencia, cuya integral (Ec 3-4) da como resultado la potencia media estimada para el periodo considerado. La ventaja de este método es su simplicidad. El método puede utilizarse para realizar una estimación global de la energía producida, así como para analizar su sensibilidad frente a diversos parámetros de interés, como por ejemplo, las velocidades características de funcionamiento de las aeroturbinas. Carta J.A., Ramírez P., Velázquez S [90], analizan la influencia del nivel de ajuste de los parámetros de la función de densidad en la estimación de la energía eléctrica generada por un aerogenerador.

Este método es probablemente el más ampliamente divulgado en prácticamente todas las revistas internacionales relacionadas con las energías renovables [91-95]

(Ec 3-4) $$\overline{\mathrm{P}} = \int_{v_a}^{v_p} P(v)\, f(v)\, dv$$

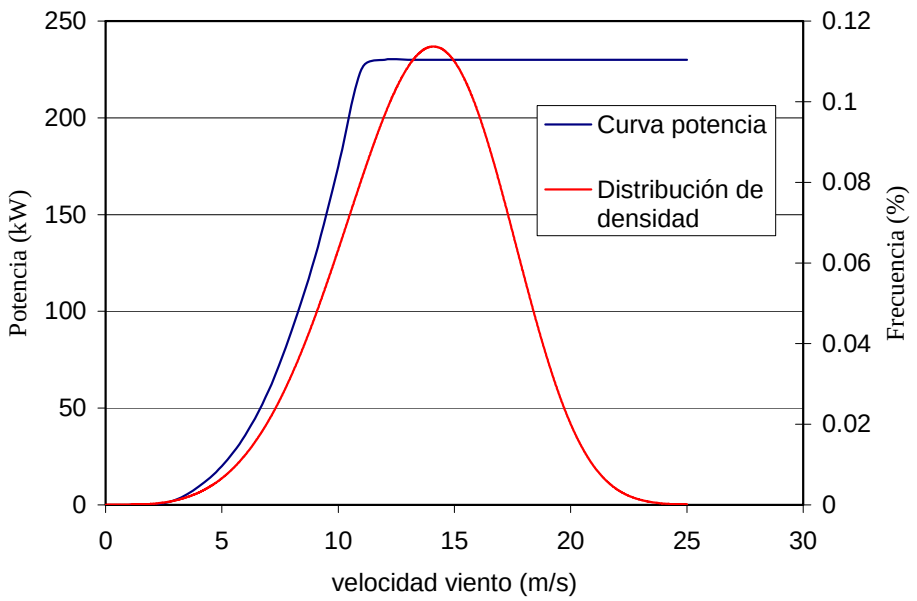

Figura 3.11:Acoplamiento curva de potencia-distribución de densidad de probabilidad

Algunos autores utilizan curvas de potencia-velocidad idealizadas [32,96-100] con formas lineales, cuadráticas, cúbicas, incluso de más alta potencia o combinación de éstas.

Sin embargo, ya que los fabricantes de aerogeneradores proporcionan de forma discretizada (en *N* puntos) la curva de potencia velocidad de sus máquinas es posible utilizarlas en la ecuación (Ec 3-4) si se realiza una aproximación. Dicha aproximación consiste en suponer lineal la variación entre dos puntos de la curva de potencia-velocidad. Se tendrá pues que dados dos puntos "*i*" e "*i*+1", la expresión de la potencia en este intervalo, en función de la velocidad podrá ser escrita como:

(Ec 3-5) $$P(v) = \frac{P_{i+1} - P_i}{v_{i+1} - v_i}\left(v - v_i\right) + P_i$$

Luego, sustituyendo en (Ec 3-4) la expresión de la potencia media podrá ser calculada de la siguiente forma:

(Ec 3-6) $$\overline{\mathrm{P}} = \sum_{i=1}^{N-1}\left\{\int_{v_i}^{v_{i+1}} f(v)\left[\frac{P_{i+1} - P_i}{v_{i+1} - v_i}\left(v - v_i\right) + P_i\right]dv\right\}$$

La estimación de la energía producida se realiza mediante (Ec 3-7), donde *T* es el periodo de tiempo considerado.

(Ec 3-7) $$\overline{E} = T\overline{P}$$

Con este método puede también estimarse el denominado "factor de capacidad", *CF*. Es decir, el porcentaje de tiempo que una turbina tendría que haber estado funcionando a la potencia nominal P_n para producir la misma cantidad de energía en el periodo de tiempo considerado. Dicho factor se determina en este método mediante la expresión (Ec 3-8).

(Ec 3-8) $$CF = \left(\frac{\overline{P}}{P_n}\right)100$$

Asimismo, pueden estimarse las denominadas "horas equivalentes" o "tiempo equivalente" que es la energía equivalente producida por unidad de kW de turbina eólica instalada

(Ec 3-9) $$t_e = \left(\frac{\overline{E}}{P_n}\right)\left(\frac{kWh}{kW}\right)$$

En la figura 3.12 se muestra un diagrama de bloques básico del procedimiento seguido para estimar la potencia media, la energía media, el factor de capacidad y el tiempo equivalente utilizando este método.

Como puede observarse, el proceso se inicia con la lectura de las velocidades de viento v_i, que representan el régimen de vientos de actúa sobre una determinada turbina eólica. El procedimiento de toma de datos de viento y su almacenamiento se indican en el capítulo 2 de esta tesis.

El siguiente paso consiste en la extrapolación de las velocidades de viento, registradas a una altura de referencia h_r, hasta la altura del eje del rotor h_e de la turbina considerada.

El tercer paso del proceso consiste en la determinación de la ley de densidad de probabilidad que mejor describa el régimen de vientos considerado. Este paso se compone de tres etapas.

En la primera etapa se selecciona la ley de densidad de probabilidad que se desea ensayar. Las distribuciones de densidad de probabilidad utilizadas hasta el momento para describir regimenes de viento, así como otras aún no ensayadas se indican en los capítulos 2 de esta tesis

En la segunda etapa se elige el método para determinar los parámetros de la ley de distribución seleccionada en la primera etapa.

En la tercera etapa se utiliza un test de ajuste para estimar, con una cierta probabilidad, si la muestra ensayada procede o no de una población que sigue la ley de distribución considerada.

En el cuarto paso se obtienen los resultados solicitados haciendo uso de las ecuaciones (Ec 3-6), a (Ec 3-9).

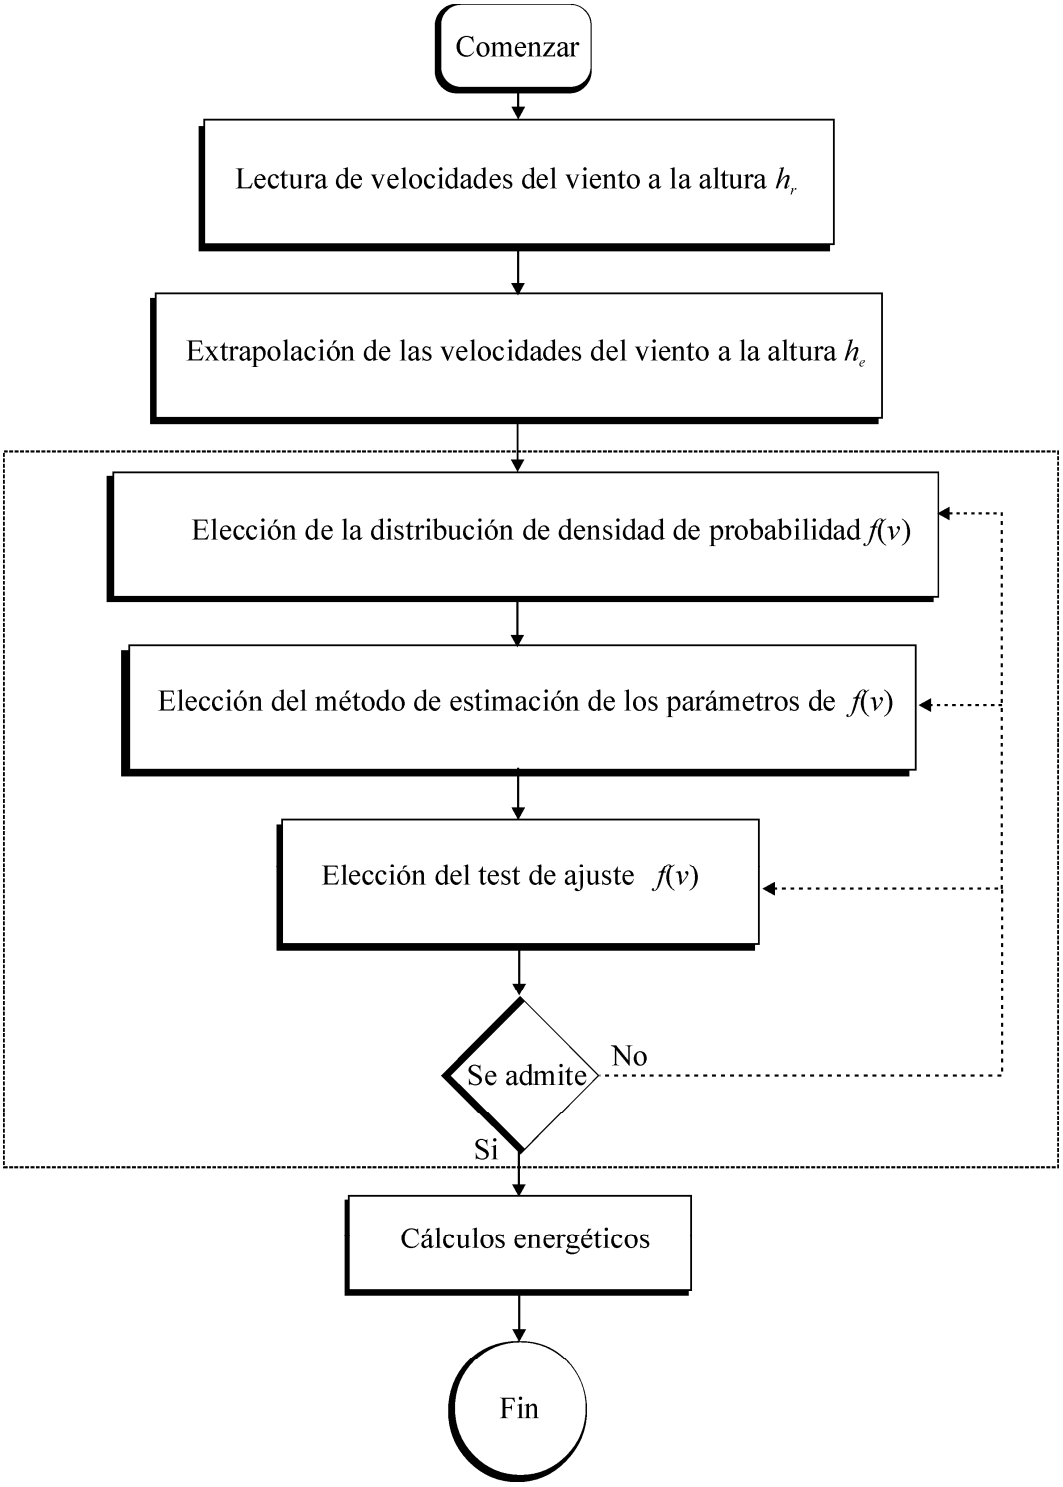

Figura 3.12:Diagrama de bloques del procedimiento que se utiliza con este método

3.3.2 Método cuasidinámico.

En este método se parte de una serie temporal de velocidades medias de viento v_i, la cual se compara con la curva característica potencia-velocidad de un aerogenerador $P(v)$[14] (Figura 3.13) para obtener una serie temporal de la potencia eléctrica, $P_i=P(v_i)$. A partir de estas últimas se puede determinar la potencia media dentro de un intervalo de tiempo t (Ec 3-10) así como la energía eléctrica (Ec 3-11).

La ventaja de este método es que puede proporcionar información acerca de los arranques y paradas experimentados por la aeroturbina, así como, mediante los datos adecuados, investigar sobre las estrategias de arranques y paradas en el funcionamiento de la aeroturbina.

(Ec 3-10) $$\overline{P} = 1/n \sum_{i=1}^{n} P(v_i)$$

(Ec 3-11) $$E = \overline{P} \times t$$

Donde:

t, es el intervalo de tiempo evaluado

n, es el número de datos existentes dentro del intervalo de tiempo t

Con este método puede también estimarse el denominado “factor de capacidad”, *CF,* y “tiempo equivalente”, haciendo uso de las ecuaciones (Ec 3-8) y (Ec 3-9).

[14] Utilizando la expresión (Ec 3-5)

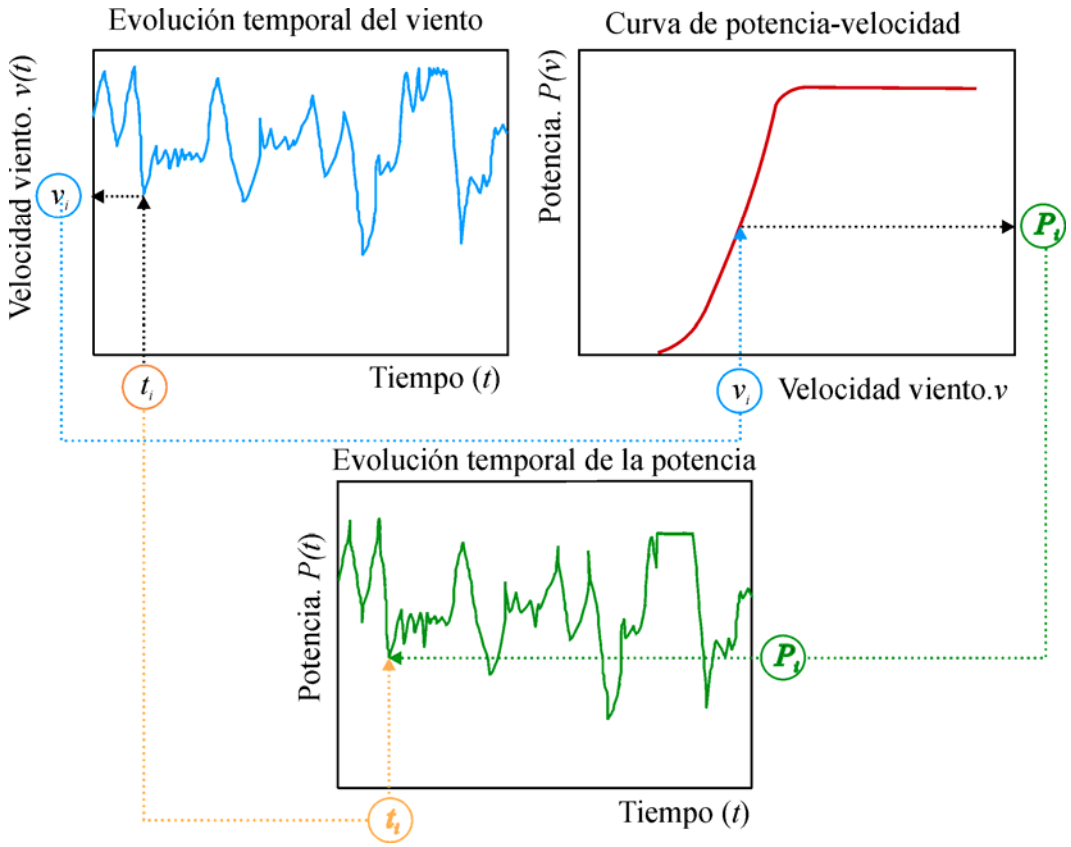

Figura 3.13:Estimación de la variación temporal de la potencia generada

Este método, debido a la ventaja anteriormente señalada, ha sido ampliamente utilizado en la modelización del funcionamiento de diversos sistemas que operan con energía eólica, ya sean sistemas híbridos [87,101-103] o aislados [104,105]

3.3.3 Método dinámico.

En este método se utiliza una serie temporal de velocidades de viento v_i como entrada a un modelo numérico de funcionamiento de la aeroturbina [85,86]. De este modo pueden obtenerse de una forma más fiables la energía producida, el número de arranques y paradas, así como llevar a cabo investigaciones sobre el efecto de diversas opciones o cambios en la estrategia de control de la aeroturbina.

3.4 Sistemas de explotación de la energía eólica. Los Parques Eólicos

En el capítulo 2 de la presente tesis se establecieron las bases para el análisis del potencial eólico de una zona en cuestión. El objetivo era analizar las características del viento y su potencialidad teniendo en cuenta fundamentalmente 3 parámetros de éste: la velocidad, la dirección y la densidad. Ya en este capítulo y en los apartados anteriores se han descrito los sistemas de captación de dicha energía eólica para su transformación concretamente en energía eléctrica. Se describieron las características fundamentales de los aerogeneradores. Posteriormente se expresó la metodología para el cálculo de la energía eléctrica de origen eólico generada por un aerogenerador a partir de las curvas de distribución de frecuencia de velocidades de la zona y la de funcionamiento del aerogenerador.

Para la explotación del aprovechamiento de la energía eólica se instalan los denominados parques eólicos. El Parque Eólico se puede definir como la instalación capaz de producir energía eléctrica utilizando como energía primaria la contenida en el viento. Estará constituido por un aerogenerador o agrupación de éstos [5].

La energía eléctrica total generada por un parque eólico se podría expresar, en principio, como la suma de las energías generadas por cada uno de los aerogeneradores que lo constituyen. A partir de dicho cálculo, para la estimación de la energía real neta del parque habría que considerar además los siguientes aspectos:

- Las pérdidas energéticas por la estela (sombras) existentes entre los diferentes aerogeneradores así como de los obstáculos presentes en la zona de implantación.
- Las pérdidas energéticas por indisponibilidad de cada aerogenerador por problemas propios de éste.
- Las pérdidas energéticas por indisponibilidad de la red eléctrica a la que está conectada el parque eólico.
- Las pérdidas eléctricas en la red interna del parque eólico.

En términos generales la vida útil de una instalación eólica es de 20 años. Es por ello la importancia, a la hora de estimar la energía eléctrica producida por un parque eólico, partir de la información eólica a largo plazo. Por lo tanto aún cuando se disponga de información eólica en la estación candidata de un corto periodo de tiempo, generalmente un año, se hace indispensable obtener a partir de estos datos y con los datos a largo plazo de otras estaciones de referencia, los datos eólicos a largo plazo de la estación candidata. A partir de la estimación

de los mismos y con la curva de funcionamiento del aerogenerador se obtendría la energía eléctrica a largo plazo en el emplazamiento en cuestión.

El cálculo de la potencia eléctrica media a largo plazo en frecuencias pequeñas, menores o iguales a la hora, facilita la toma de decisiones antes diferentes obligaciones en el proceso de explotación de un parque eólico. A modo de ejemplo enumerar las siguientes:

1. El artículo 20 del Decreto 32/2006 [5] menciona la obligación del titular de una instalación eólica durante el periodo de explotación de la misma de adoptar las medidas correctoras oportunas en caso de no alcanzar el nivel de eficiencia energética establecido para la instalación. Para este caso es obvio que el grado de incertidumbre con la estimación energética a largo plazo (con la información eólica de muchos años) es mucho menor que si el mismo se realiza con los datos de un año exclusivamente.
2. El artículo 26 del Decreto 32/2006 [5] establece que la Consejería competente en materia de energía podrá exigir al titular de la instalación eólica, para la aprobación del proyecto, un estudio de estabilidad en la que se analice la afección de la instalación sobre la red eléctrica a la cual se conecte.

   El disponer de la información de la potencia eléctrica a largo plazo generalizará el comportamiento de la instalación eólica al periodo de vida de la misma no centrándose exclusivamente al periodo en el cual se realizó la medida de los datos meteorológicos.
3. Los ingresos de una instalación eólica, y por lo tanto la viabilidad económica de la misma, se fundamentan exclusivamente en la estimación de la energía eléctrica del parque eólico y del precio unitario de la misma. El precio viene regulado por el Real Decreto 661/2007 [3] que garantiza el mismo, en uno valores, durante el periodo de vida de la instalación. Es obvio que la estimación de la energía a partir de los datos eólicos a largo plazo garantizan unos resultados más reales en el horizonte temporal de la vida de la instalación, que si el cálculo se realiza simplemente a partir de la información eólica a corto plazo, generalmente un año. Esto es debido la variación interanual que sufren las condiciones eólicas en todo emplazamiento ya comentado en el capítulo 1 de la presente tesis.

En términos generales, se pueden diferenciar tres modos de explotación de la energía eólica a través de los parques eólicos:

- ✓ Parque Eólicos interconectados con la red eléctrica
- ✓ Parques eólicos en sistemas aislados
- ✓ Parques eólicos con consumos asociados

3.4.1 Parques eólicos interconectados con la red eléctrica

Se ha definido de esta manera a aquellos sistemas eólicos que tienen sus grupos normalmente trabajando en paralelo con la red eléctrica y vuelca a la misma toda la energía que genera.
Es el modo de explotación más común en este tipo de instalaciones. La regulación de este tipo de instalaciones queda definida por diferentes documentos legislativos. A nivel de la totalidad del territorio español se tiene, entre los que le aplican de forma directa, el Real Decreto 661/2007 [3] y la Resolución de 4 de Octubre de 2006 [4]. Para el caso particular de la archipiélago Canario, adicionalmente se encuentra el Decreto 32/2006 [5] y la Orden de 15 de Noviembre de 2006 [106]. En la figura 3.14 se puede observa un esquema general explicativo de la conexión del parque eólico en este modo de explotación.

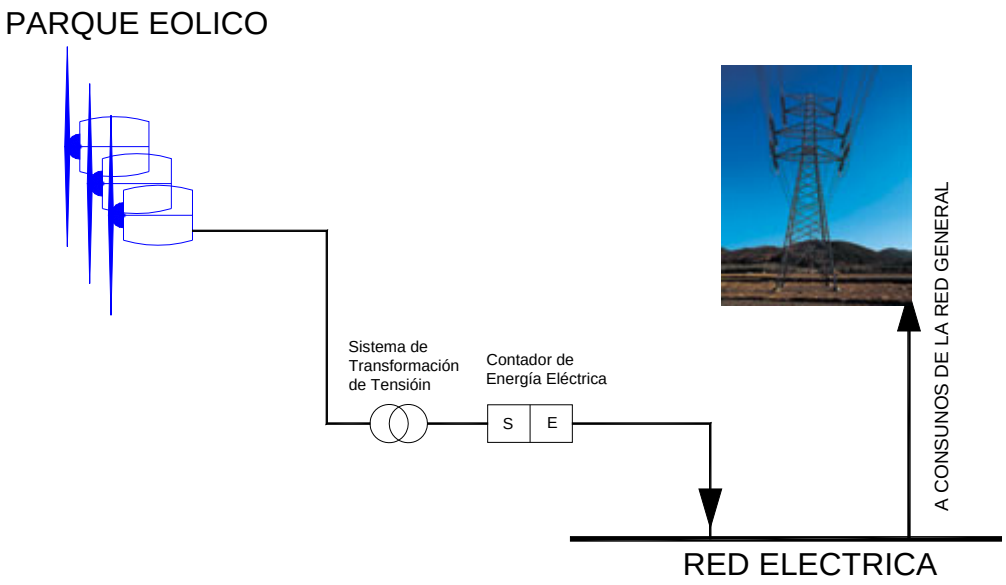

Figura 3.14:Esquema de Parque Eólico interconectado con la red eléctrica

3.4.2 Parques eólicos en sistemas aislados

Este tipo de instalaciones suelen ser realizadas en zonas muy alejadas del trazado de la red general de distribución eléctrica. El tamaño y tipo de instalación depende únicamente de las necesidades de potencia eléctrica del usuario de la instalación y es característico en ellos que la instalación se sitúe muy cerca del centro de consumo, requiriéndose frecuentemente la existencia de sistemas de acumulación de energía eléctrica (grupo de baterías).

Al depender en cada momento la producción del parque eólico de las necesidades en la demanda así como del sistema de acumulación que se disponga, en este tipo de instalaciones se hace más necesario el conocer de forma fiable la potencia eléctrica que genera en cada momento la instalación eólica para la regulación de la oferta en relación a la demanda. En la figura 3.15 se puede observa un esquema general explicativo de la conexión del parque eólico en este modo de explotación.

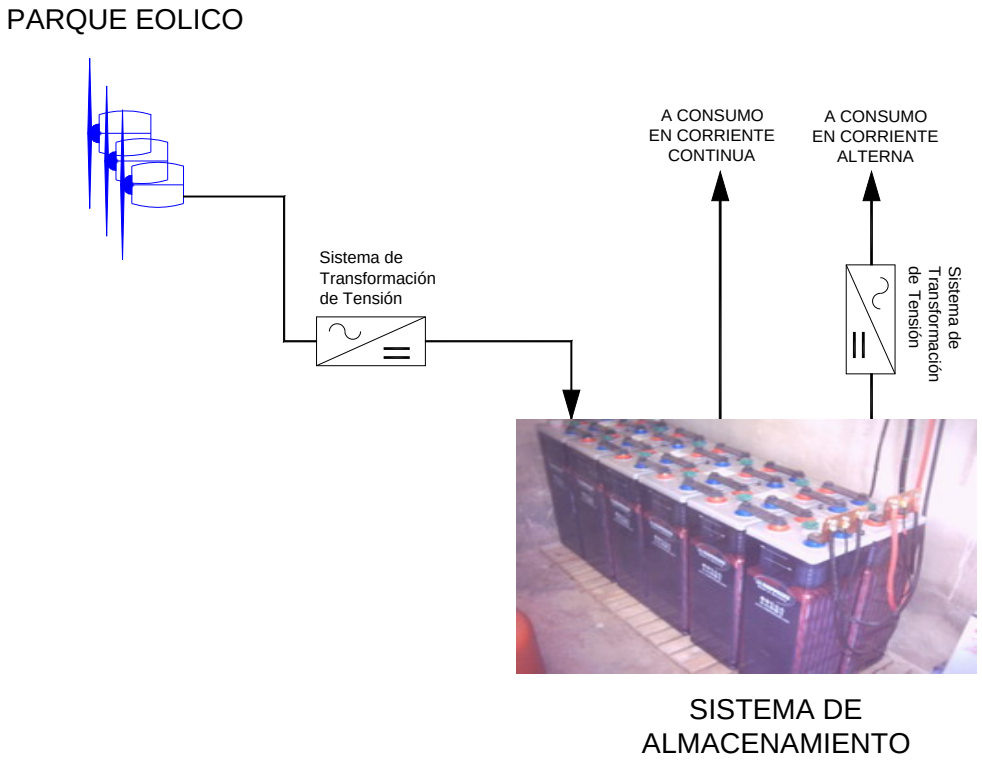

Figura 3.15:Esquema de Parque Eólico en Sistema Aislado

3.4.3 Parques eólicos con consumos asociados

Se define como aquel que tiene sus grupos aerogeneradores conectados en paralelo con la red eléctrica, siendo la energía generada mayoritariamente para su autoconsumo en instalaciones receptoras propias, pudiendo recibir de la red cierta cantidad de energía así como entregar sus excedentes. Deberá estar permanentemente conectado a la instalación eléctrica de consumo mediante una línea directa independiente de la red.

Este modo de explotación de los parques eólicos es reconocido exclusivamente en las instalaciones a ubicar en el archipiélago canario. Está regulado por el artículo 8 del Decreto 32/2006 [5]. En la figura 3.16 se puede observa un esquema general explicativo de la conexión del parque eólico en este modo de explotación.

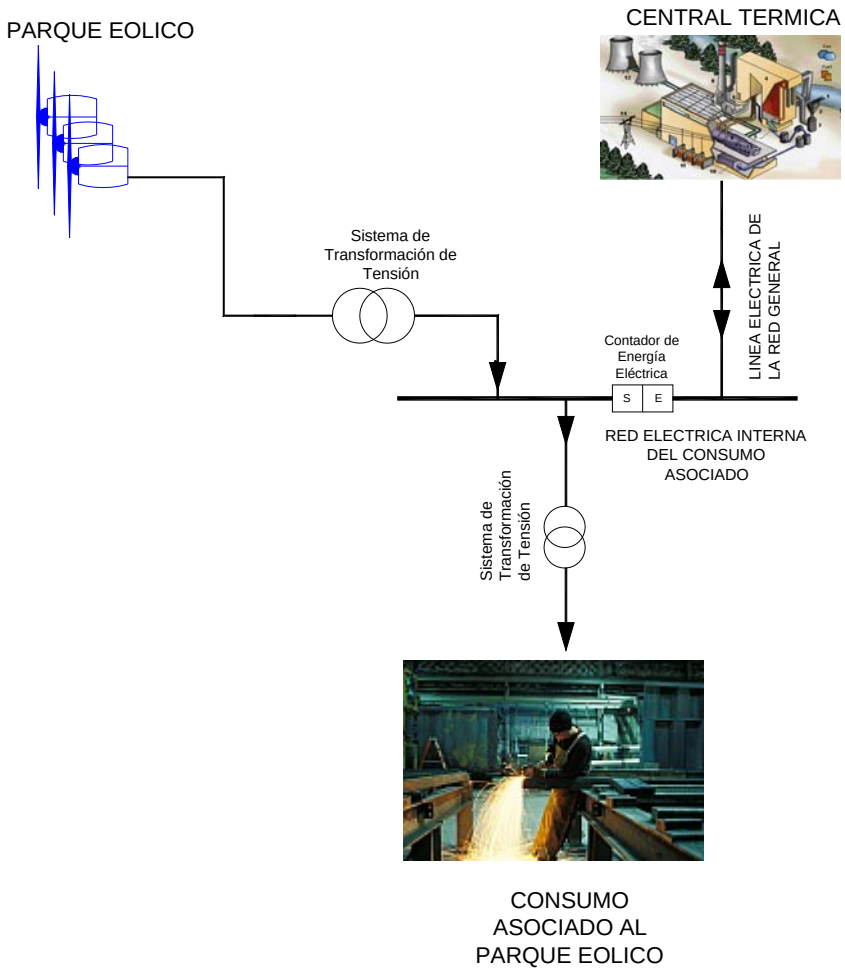

Figura 3.16:Esquema de Parque Eólico con Consumo Asociado

CAPITULO 4

Fundamentos de las Redes Neuronales

INDICE

4 FUNDAMENTOS DE LAS REDES NEURONALES 79
4.1 Introducción a las redes neuronales 79
4.2 Funcionamiento de una neurona biológica 81
4.3 Características de una red neuronal artificial 86
4.3.1 Notación: 88
4.3.2 Funciones de Transferencia: 89
4.3.2.1 Limitador fuerte (Hardlim): 90
4.3.2.2 Función de transferencia lineal (purelin): 91
4.3.2.3 Función de transferencia sigmoidal (logsig): 92
4.3.3 Topología de una Red: 92
4.4 Principales tipos de redes neuronales 99
4.4.1 Perceptrón 99
4.4.1.1 Antecedentes: 99
4.4.1.2 Estructura de la red: 103
4.4.2 Adaline 104
4.4.2.1 Antecedentes: 104
4.4.2.2 Estructura de la red: 106
4.4.3 Backpropagation 107
4.4.3.1 Antecedentes: 107
4.4.3.2 Estructura de la Red: 110
4.4.3.3 Regla de Aprendizaje 111
4.4.3.3.1 Red Backpropagation con momentum: 122
4.4.3.3.1.1 Red Backpropagation con rata de aprendizaje variable: 125
4.4.3.3.2 . Método del Gradiente Conjugado: 127
4.4.3.3.3 Algoritmo de Levenberg - Marquardt: 128

4 FUNDAMENTOS DE LAS REDES NEURONALES

4.1 *Introducción a las redes neuronales*

Resulta irónico pensar que máquinas de cómputo capaces de realizar 100 millones de operaciones en coma flotante por segundo, no sean capaces de entender el significado de las formas visuales o de distinguir entre distintas clases de objetos. Los sistemas de computación secuencial, son exitosos en la resolución de problemas matemáticos o científicos, en la creación, manipulación y mantenimiento de bases de datos, en comunicaciones electrónicas, en el procesamiento de textos, gráficos y auto edición, incluso en funciones de control de electrodomésticos, haciéndolos más eficientes y fáciles de usar, pero definitivamente tienen una gran incapacidad para interpretar el mundo.

Esta dificultad de los sistemas de computo que trabajan bajo la filosofía de los sistemas secuenciales, desarrollados por Von Neuman, ha hecho que un gran número de investigadores [108-113] centre su atención en el desarrollo de nuevos sistemas de tratamiento de la información, que permitan solucionar problemas cotidianos, tal como lo hace el cerebro humano; este órgano biológico cuenta con varias características deseables para cualquier sistema de procesamiento digital, tales como:

1. Es robusto y tolerante a fallas, diariamente mueren neuronas sin afectar su desempeño.
2. Es flexible, se ajusta a nuevos ambientes por aprendizaje, no hay que programarlo.
3. Puede manejar información difusa, con ruido o inconsistente.
4. Es altamente paralelo
5. Es pequeño, compacto y consume poca energía.

El cerebro humano constituye una computadora muy notable, es capaz de interpretar información imprecisa suministrada por los sentidos a un ritmo increíblemente veloz. Logra discernir un susurro en una sala ruidosa, un rostro en un callejón mal iluminado y leer entre líneas un discurso; lo más impresionante de todo, es que el cerebro aprende sin instrucciones explícitas de ninguna clase, a crear las representaciones internas que hacen posibles estas habilidades.

Basados en la eficiencia de los procesos llevados a cabo por el cerebro, e inspirados en su funcionamiento, varios investigadores han desarrollado desde hace más de 30 años la teoría de las Redes Neuronales Artificiales (RNA), las cuales emulan las redes neuronales biológicas,

y que se han utilizado para aprender estrategias de solución basadas en ejemplos de comportamiento típico de patrones; estos sistemas no requieren que la tarea a ejecutar se programe, ellos generalizan y aprenden de la experiencia.

La teoría de las RNA ha brindado una alternativa a la computación clásica, para aquellos problemas, en los cuales los métodos tradicionales no han entregado resultados muy convincentes, o poco convenientes. Las aplicaciones más exitosas de las RNA son:

1. Procesamiento de imágenes y de voz
2. Reconocimiento de patrones
3. Planeamiento
4. Interfaces adaptativas para sistemas Hombre/máquina
5. Predicción
6. Control y optimización
7. Filtrado de señales

Los sistemas de computo tradicional procesan la información en forma secuencial; un computador serial consiste por lo general de un solo procesador que puede manipular instrucciones y datos que se localizan en la memoria, el procesador lee, y ejecuta una a una las instrucciones en la memoria; este sistema serial es secuencial, todo sucede en una sola secuencia determinística de operaciones. Las RNA no ejecutan instrucciones, responden en paralelo a las entradas que se les presenta. El resultado no se almacena en una posición de memoria, este es el estado de la red para el cual se logra equilibrio. El conocimiento de una red neuronal no se almacena en instrucciones, el poder de la red está en su topología y en los valores de las conexiones (pesos) entre neuronas.

Las RNA son una teoría que aún esta en proceso de desarrollo, su verdadera potencialidad no se ha alcanzado todavía; aunque los investigadores han desarrollado potentes algoritmos de aprendizaje de gran valor práctico, las representaciones y procedimientos de que se sirve el cerebro, son aún desconocidas. Tarde o temprano los estudios computacionales del aprendizaje con RNA acabarán por converger a los métodos descubiertos por evolución, cuando eso suceda, muchos datos empíricos concernientes al cerebro comenzarán súbitamente a adquirir sentido y se tornarán factibles muchas aplicaciones desconocidas de las redes neuronales.

4.2 Funcionamiento de una neurona biológica

El cerebro consta de un gran número (aproximadamente 10^{11}) de elementos altamente interconectados (aproximadamente 10^4 conexiones por elemento), llamados neuronas. Estas neuronas tienen tres componentes principales, las dendritas, el cuerpo de la célula o soma, y el axón. Las dendritas, son el árbol receptor de la red, son como fibras nerviosas que cargan de señales eléctricas el cuerpo de la célula. El cuerpo de la célula, realiza la suma de esas señales de entrada. El axón es una fibra larga que lleva la señal desde el cuerpo de la célula hacia otras neuronas. El punto de contacto entre un axón de una célula y una dendrita de otra célula es llamado sinápsis, la longitud de la sinápsis es determinada por la complejidad del proceso químico que estabiliza la función de la red neuronal. Un esquema simplificado de la interconexión de dos neuronas biológicas se observa en la figura 4.1

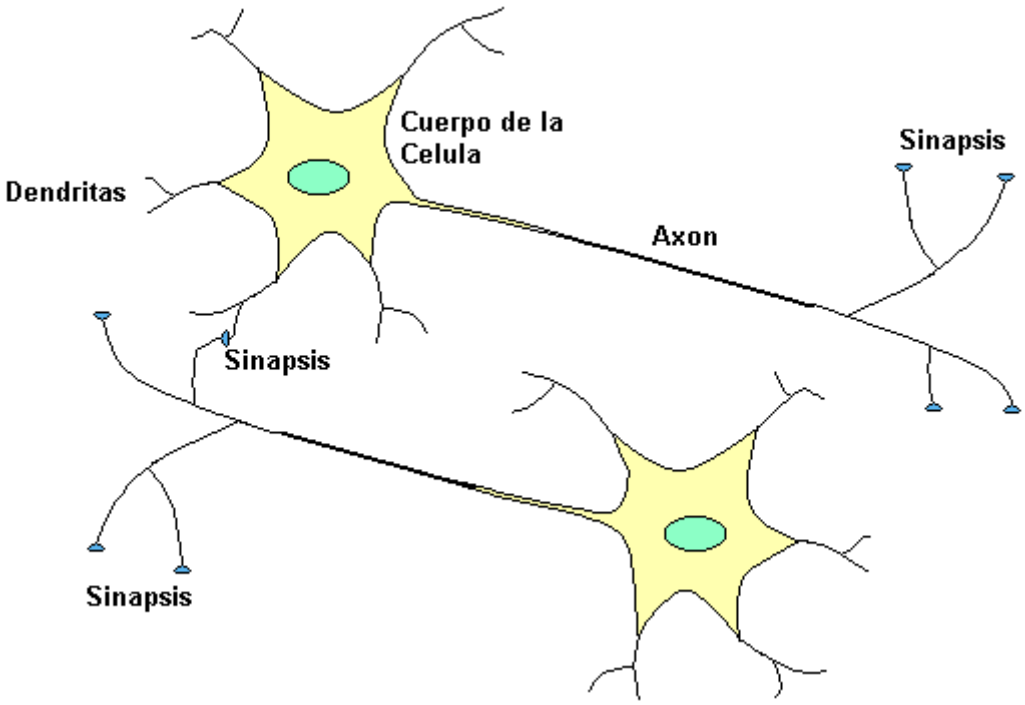

Figura 4.1:Neuronas Biológicas

Algunas de las estructuras neuronales son determinadas en el nacimiento, otra parte es desarrollada a través del aprendizaje, proceso en que nuevas conexiones neuronales son realizadas y otras se pierden por completo. El desarrollo neurológico se hace crítico durante los primeros años de vida, por ejemplo está demostrado que si a un cachorro de gato, se le impide usar uno de sus ojos durante un periodo corto de tiempo, el nunca desarrollara una visión normal en ese ojo.

Las estructuras neuronales continúan cambiando durante toda la vida, estos cambios consisten en el refuerzo o debilitamiento de las uniones sinápticas; por ejemplo se cree que nuevas memorias son formadas por la modificación de esta intensidad entre sinápsis, así el proceso de recordar el rostro de un nuevo amigo, consiste en alterar varias sinápsis.

Como consecuencia de los primeros estudios sobre la base neural de los sistemas mnémicos (relacionados con la memoria), se creía que el almacenamiento de la memoria asociativa, tanto implícita como explícita, requerían de un circuito neuronal muy complejo. Entre quienes comenzaron a oponerse a este enfoque se hallaba Donald O. Hebb, profesor de la universidad de Milner; Hebb sugirió que el aprendizaje asociativo podría ser producido por un mecanismo celular sencillo y propuso que las asociaciones podrían formarse por una actividad neuronal coincidente: "Cuando un axón de la célula A excita la célula B y participa en su activación, se produce algún proceso de desarrollo o cambio metabólico en una o en ambas células, de suerte que la eficacia de A, como célula excitadora de B, se intensifica". Según la regla Hebbiana de aprendizaje, el que coincida la actividad de las neuronas presinápticas (suministran el impulso de entrada) con la de las postsinápticas (reciben el impulso) es muy importante para que se refuerce la conexión entre ellas, este mecanismo es llamado pre-postasociativo, del cual puede observarse un ejemplo en la figura 4.2

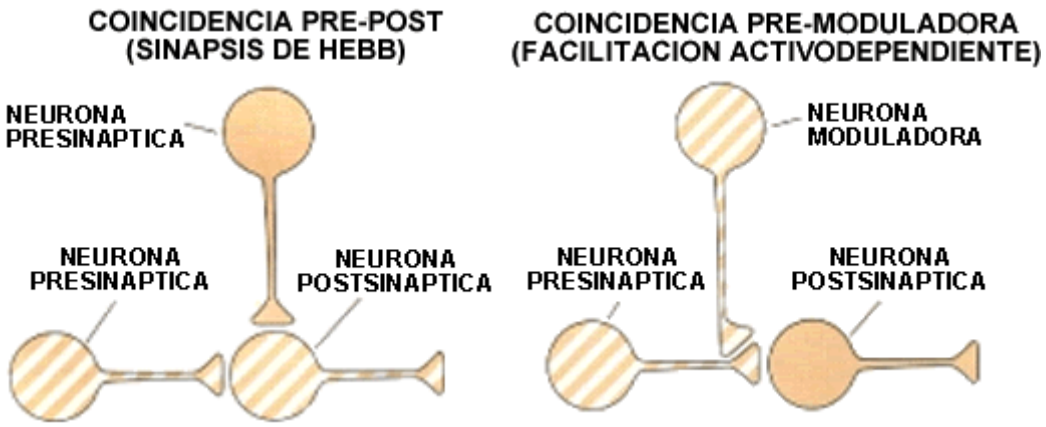

Figura 4.2:Cambios asociativos de las fuerzas sinápticas durante el aprendizaje

Todas las neuronas conducen la información de forma similar, esta viaja a lo largo de axones en breves impulsos eléctricos, denominados potenciales de acción; los potenciales de acción que alcanzan una amplitud máxima de unos 100 mV y duran 1 ms, son resultado del desplazamiento a través de la membrana celular de iones de sodio dotados de carga positiva, que pasan desde el fluido extracelular hasta el citoplasma intracelular; la concentración extracelular de sodio supera enormemente la concentración intracelular.

La membrana en reposo mantiene un gradiente de potencial eléctrico de -70mv, el signo negativo se debe a que el citoplasma intracelular está cargado negativamente con respecto al exterior; los iones de sodio no atraviesan con facilidad la membrana en reposo, los estímulos físicos o químicos que reducen el gradiente de potencial, o que despolaricen la membrana, aumentan su permeabilidad al sodio y el flujo de este ion hacia el exterior acentúa la despolarización de la membrana, con lo que la permeabilidad al sodio se incrementa más aún.

Alcanzado un potencial crítico denominado "umbral", la realimentación positiva produce un efecto regenerativo que obliga al potencial de membrana a cambiar de signo. Es decir, el interior de la célula se torna positivo con respecto al exterior, al cabo de 1 ms, la permeabilidad del sodio decae y el potencial de membrana retorna a -70mv, su valor de reposo. Tras cada explosión de actividad iónica, el mecanismo de permeabilidad del sodio se mantiene refractario durante algunos milisegundos; la tasa de generación de potenciales de acción queda así limitada a unos 200 impulsos por segundo, o menos.

Aunque los axones puedan parecer hilos conductores aislados, no conducen los impulsos eléctricos de igual forma, como hilos eléctricos no serían muy valiosos, pues su resistencia a lo largo del eje es demasiado grande y a resistencia de la membrana demasiado baja; la carga positiva inyectada en el axón durante el potencial de acción queda disipada uno o dos milímetros más adelante, para que la señal recorra varios centímetros es preciso regenerar frecuentemente el potencial de acción a lo largo del camino la necesidad de reforzar repetidamente esta corriente eléctrica limita a unos 100 metros por segundo la velocidad máxima de viaje de los impulsos, tal velocidad es inferior a la millonésima de la velocidad de una señal eléctrica por un hilo de cobre.

Los potenciales de acción, son señales de baja frecuencia conducidas en forma muy lenta, estos no pueden saltar de una célula a otra, la comunicación entre neuronas viene siempre mediada por transmisores químicos que son liberados en las sinápsis. Un ejemplo de comunicación entre neuronas y del proceso químico de la liberación de neurotransmisores se ilustra en la figura 4.3.

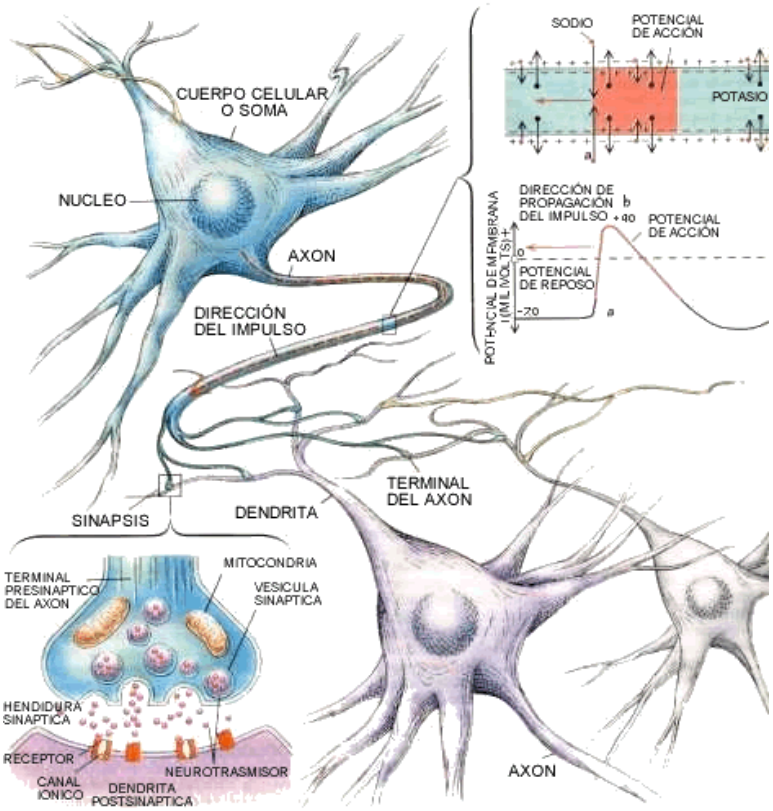

Figura 4.3:Comunicación entre neuronas

Cuando un potencial de acción llega al terminal de un axón son liberados transmisores alojados en diminutas vesículas, que después son vertidos en una hendidura de unos 20 nanómetros de anchura que separa la membrana presináptica de la postsináptica; durante el apogeo del potencial de acción, penetran iones de calcio en el terminal nervioso, su movimiento constituye la señal determinante de la exocitosis sincronizada, esto es la liberación coordinada de moléculas neurotransmisoras. En cuanto son liberados, los neurotransmisores se enlazan con receptores postsinápticos, instando el cambio de la permeabilidad de la membrana.

Cuando el desplazamiento de carga hace que la membrana se aproxime al umbral de generación de potenciales de acción, se produce un efecto excitador y cuando la membrana resulta estabilizada en la vecindad el valor de reposo se produce un efecto inhibidor. Cada sinápsis produce sólo un pequeño efecto, para determinar la intensidad (frecuencia de los potenciales de acción) de la respuesta cada neurona ha de integrar continuamente hasta unas 1000 señales sinápticas, que se suman en el soma o cuerpo de la célula.

En algunas neuronas los impulsos se inician en la unión entre el axón y el soma, y luego se transmiten a lo largo del axón a otras células nerviosas. Cuando el axón está cerca de sus

células destino, se divide en muchas ramificaciones que forman sinápsis con el soma o axones de otras células. Las sinápsis pueden ser excitatorias o inhibitorias según el neurotransmisor que se libere, cada neurona recibe de 10.000 a 100.000 sinápsis y su axón realiza una cantidad similar de sinápsis.

Las sinápsis se clasifican según su posición en la superficie de la neurona receptora en tres tipos: axo-somática, axo-dendrítica, axo-axónica. Los fenómenos que ocurren en la sinápsis son de naturaleza química, pero tienen efectos eléctricos laterales que se pueden medir.

En la figura 4.4 se visualiza el proceso químico de una sinápsis y los diferentes elementos que hacen parte del proceso tanto en la neurona presináptica, como en la postsináptica.

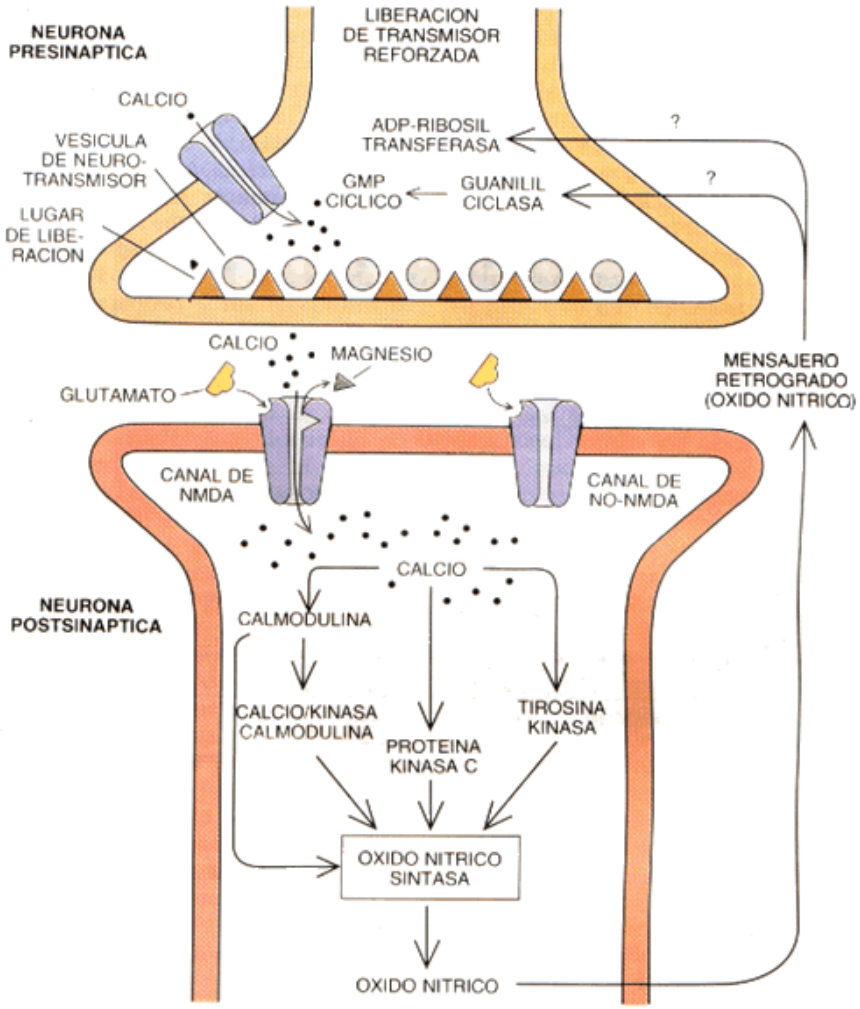

Figura 4.4:Proceso químico de una sinápsis

Las RNA no alcanzan la complejidad del cerebro, sin embargo hay dos aspectos similares entre redes biológicas y artificiales, primero los bloques de construcción de ambas redes son sencillos elementos computacionales (aunque las RNA son mucho más simples que las biológicas) altamente interconectados; segundo, las conexiones entre neuronas determinan la función de la red.

4.3 Características de una red neuronal artificial

El modelo de una neurona artificial es una imitación del proceso de una neurona biológica, puede también asemejarse a un sumador hecho con un amplificador operacional tal como se ve en la figura 4.5

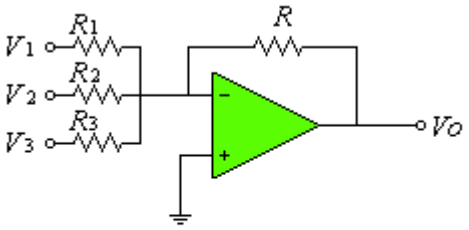

$$Vo = -\sum_{i=1}^{n} \frac{R}{Ri} Vi$$

Figura 4.5:Neurona Artificial

Existen varias formas de nombrar una neurona artificial, es conocida como nodo, neuronodo, celda, unidad o elemento de procesamiento (PE); En la figura 4.6 se observa un PE en forma general y su similitud con una neurona biológica

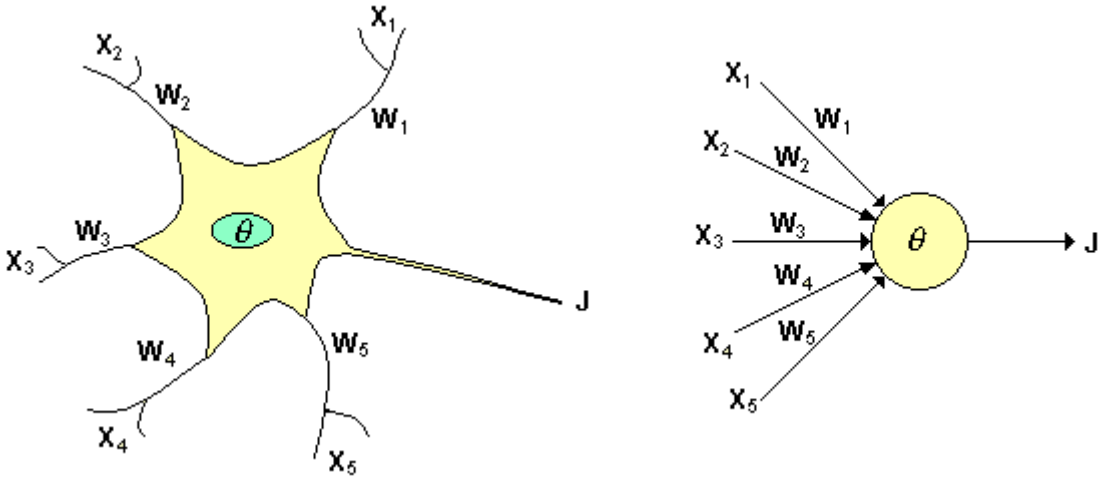

Figura 4.6:De la neurona biológica a la neurona artificial

De la observación detallada del proceso biológico se han hallado los siguientes análogos con el sistema artificial:

- Las entradas X_i representan las señales que provienen de otras neuronas y que son capturadas por las dendritas.
- Los pesos W_i son la intensidad de la sinápsis que conecta dos neuronas; tanto X_i como W_i son valores reales.
- θ,es la función umbral que la neurona debe sobrepasar para activarse; este proceso ocurre biológicamente en el cuerpo de la célula.

Las señales de entrada a una neurona artificial $X_1, X_2,.., X_n$ son variables continuas en lugar de pulsos discretos, como se presentan en una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, llamado peso sináptico o fortaleza de la conexión cuya función es análoga a la de la función sináptica de la neurona biológica. Los pesos pueden ser positivos (excitatorios), o negativos (inhibitorios), el nodo sumatorio acumula todas las señales de entradas multiplicadas por los pesos o ponderadas y las pasa a la salida a través de una función umbral o función de transferencia. La entrada neta a cada unidad puede escribirse de la siguiente manera

(Ec 4-1) $$neta_i = \sum_{i=1}^{n} W_i X_i = \overrightarrow{X}\overrightarrow{W}$$

Una idea clara de este proceso se muestra en la figura 4.7, en donde puede observarse el recorrido de un conjunto de señales que entran a la red.

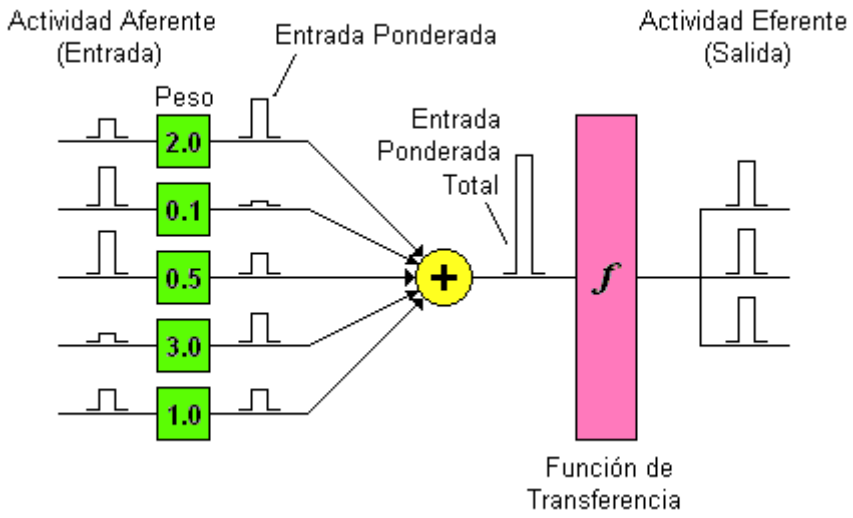

Figura 4.7:Proceso de una red neuronal

Una vez que se ha calculado la activación del nodo, el valor de salida equivale a

(Ec 4-2) $$x_i = f_i(neta_i)$$

Donde f_i representa la función de activación para esa unidad, que corresponde a la función escogida para transformar la entrada $neta_i$ en el valor de salida, x_i, que depende de las características específicas de cada red.

4.3.1 Notación:

Una notación matemática estándar no ha sido aún establecida para las redes neuronales, ya que sus aplicaciones son útiles en muchos campos, Ingeniería, Física, Psicología y Matemáticas. En este trabajo se adoptó la siguiente convención para identificar las variables, de manera que fuera compatibles con las diferentes áreas, siendo lo más sencilla posible:

- Valores escalares: se representarán por medio de letra minúscula itálica
- Vectores: se representarán con letra itálica minúscula en negrilla.
- Matrices: se representarán con letra mayúscula itálica en negrilla.

Para redes multicapa, los parámetros adoptaran la siguiente forma:

$$W^{c}_{s^{c},s^{c}}$$

Donde c, es el número de la capa a la que corresponde dicho peso, y s representa las neuronas que participan en proceso.

Así $W^{2}_{1,1}$ representa el peso de la segunda capa que comunica la primera neurona de dicha capa con la primera neurona de la primera capa. De igual manera el peso que representa la conexión desde la última neurona de la capa dos a la última neurona de la capa uno estará representado por: $W^{2}_{s^{2},s^{1}}$

Esta convención es adoptada para todos los parámetros de la red.

4.3.2 Funciones de Transferencia:

Un modelo más académico que facilita el estudio de una neurona, puede visualizarse en la figura 4.8

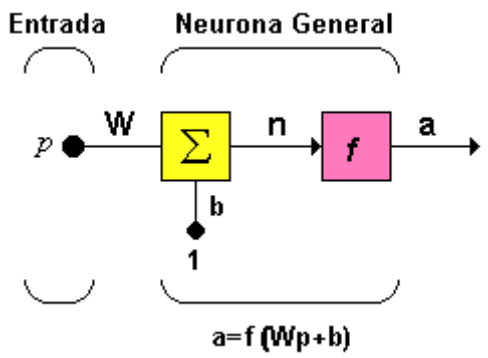

Figura 4.8:Neurona de una sola entrada

Las entradas a la red serán ahora presentadas en el vector p, que para el caso de una sola neurona contiene solo un elemento, w sigue representando los pesos y la nueva entrada b es una ganancia que refuerza la salida del sumador n, la cual es la salida neta de la red; la salida total está determinada por la función de transferencia , la cual puede ser una función lineal o no lineal de n, y que es escogida dependiendo de las especificaciones del problema que la neurona tenga que resolver; aunque las RNA se inspiren en modelos biológicos no existe

ninguna limitación para realizar modificaciones en las funciones de salida, así que se encontrarán modelos artificiales que nada tienen que ver con las características del sistema biológico.

4.3.2.1 Limitador fuerte (Hardlim):

La figura 4.9 muestra como esta función de transferencia acerca la salida de la red a cero, si el argumento de la función es menor que cero y la lleva a uno si este argumento es mayor que uno. Esta función crea neuronas que clasifican las entradas en dos categorías diferentes, característica que le permite ser empleada en la red tipo Perceptrón

(Ec 4-3) $$a = \begin{Bmatrix} 1 \text{ si } n \geq 0 \\ 0 \text{ si } n < 0 \end{Bmatrix}$$

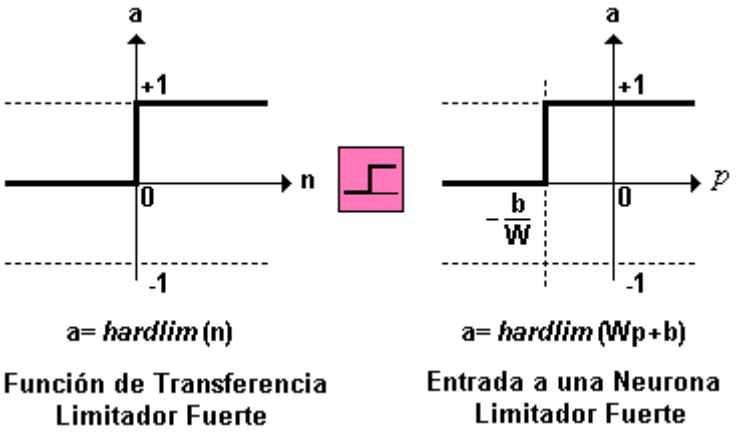

Figura 4.9:Función de transferencia Hardlim

El icono para la función Hardlim reemplazara a la letra *f* en la expresión general, cuando se utilice la función Hardlim.

Una modificación de esta función puede verse en la figura 4.10, la que representa la función de transferencia Hardlims que restringe el espacio de salida a valores entre 1 y –1.

(Ec 4-4) $$a = \begin{Bmatrix} 1 \text{ si } n \geq 0 \\ -1 \text{ si } n < 0 \end{Bmatrix}$$

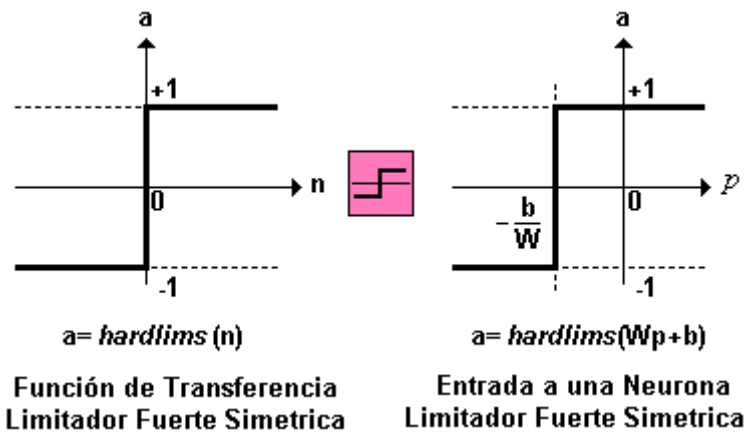

Figura 4.10:Función de transferencia Hardlims

4.3.2.2 Función de transferencia lineal (purelin):

La salida de una función de transferencia lineal es igual a su entrada: a = n

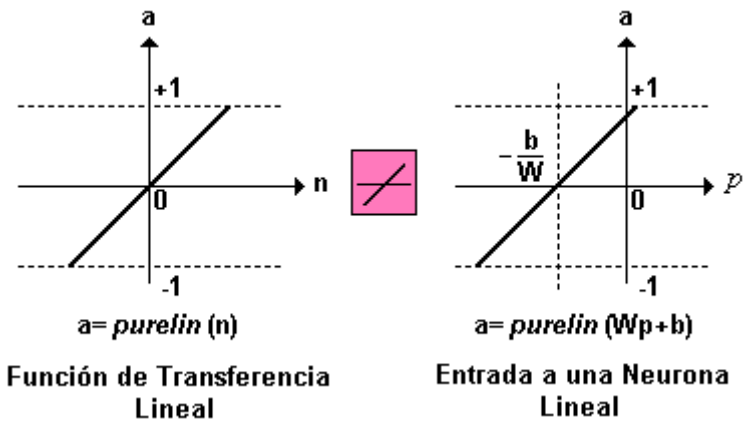

Figura 4.11:Función de transferencia lineal

En la gráfica del lado derecho de la figura 4.10, puede verse la característica de la salida, *a,* de la red, comparada con la entrada *p*, más un valor de ganancia *b*, neuronas que emplean esta función de transferencia son utilizadas en la red tipo Adaline.

4.3.2.3 Función de transferencia sigmoidal (logsig):

Esta función toma los valores de entrada, los cuales pueden oscilar entre más y menos infinito, y restringe la salida a valores entre cero y uno, de acuerdo a la expresión

(Ec 4-5) $$a = \frac{1}{1+e^{-n}}$$

Esta función es comúnmente usada en redes multicapa, como la Backpropagation, en parte porque la función logsig es diferenciable.

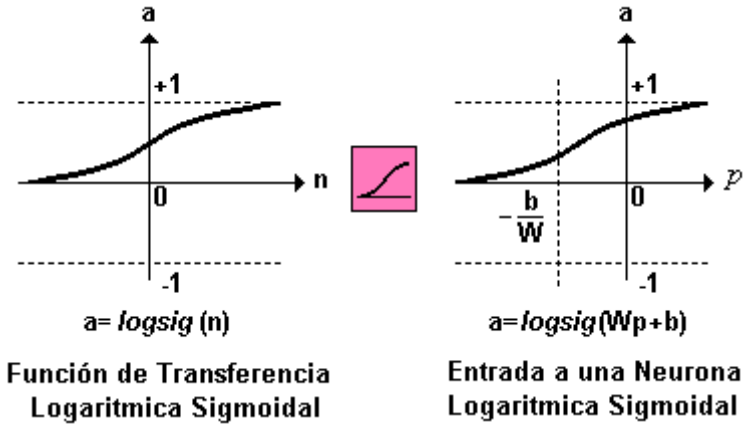

Figura 4.12:Función de transferencia sigmoidal

4.3.3 Topología de una Red:

Típicamente una neurona tiene más de una entrada; en la figura 4.13 se observa una neurona con R entradas; las entradas individuales $p_1,p_2,...,p_R$ son multiplicadas por los pesos correspondientes $w_{1,1}$, $w_{1,2}$,...$w_{1,R}$ pertenecientes a la matriz de pesos *W*.

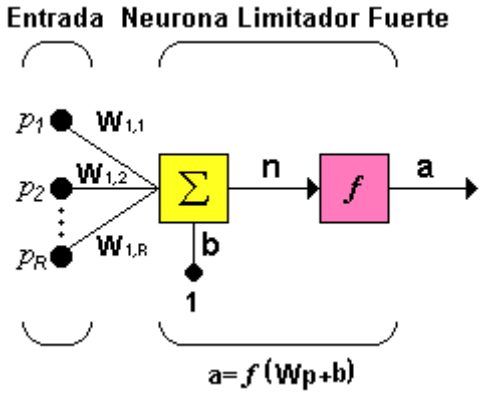

Figura 4.13:Neurona con múltiples entradas

La neurona tiene una ganancia *b,* la cual llega al mismo sumador al que llegan las entradas multiplicadas por los pesos, para formar la salida *n*,

(Ec 4-6) $$n = w_{1,1}p_1 + w_{1,2}p_2 + \ldots + w_{1,R}p_R + b$$

Esta expresión puede ser escrita en forma matricial

(Ec 4-7) $$n = W_p + b$$

Los subíndices de la matriz de pesos representan los términos involucrados en la conexión, el primer subíndice representa la neurona destino y el segundo, representa la fuente de la señal que alimenta a la neurona. Por ejemplo, los índices de $w_{1,2}$ indican que este peso es la conexión desde la segunda entrada a la primera neurona. Esta convención se hace más útil cuando hay más de una neurona, o cuando se tiene una neurona con demasiados parámetros; en este caso la notación de la figura 4.13, puede resultar inapropiada y se prefiere emplear la notación abreviada representada en la figura 4.14

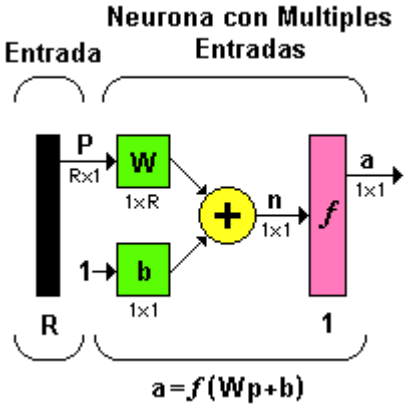

Figura 4.14:Neurona con múltiples entradas, notación abreviada

El vector de entrada *p* es representado por la barra sólida vertical a la izquierda. Las dimensiones de *p* son mostradas en la parte inferior de la variable como Rx1, indicando que el vector de entrada es un vector fila de R elementos. Las entradas van a la matriz de pesos *W*, la cual tiene R columnas y solo una fila para el caso de una sola neurona. Una constante 1 entra a la neurona multiplicada por la ganancia escalar *b*. La salida de la red *a*, es en este caso un escalar, si la red tuviera más de una neurona *a* sería un vector.

Dentro de una red neuronal, los elementos de procesamiento se encuentran agrupados por capas, una capa es una colección de neuronas; de acuerdo a la ubicación de la capa en la RNA, esta recibe diferentes nombres

Capa de entrada: Recibe las señales de la entrada de la red, algunos autores no consideran el vector de entrada como una capa pues allí no se lleva a cabo ningún proceso.

Capas ocultas: Estas capas son aquellas que no tienen contacto con el medio exterior, sus elementos pueden tener diferentes conexiones y son estas las que determinan las diferentes topologías de la red

Capa de salida: Recibe la información de la capa oculta y transmite la respuesta al medio externo.

Una red de una sola capa con un número *S* de neuronas, se observa en la figura 4.15 en la cual, cada una de las R entradas es conectada a cada una de las neuronas, la matriz de pesos tiene ahora *S* filas.

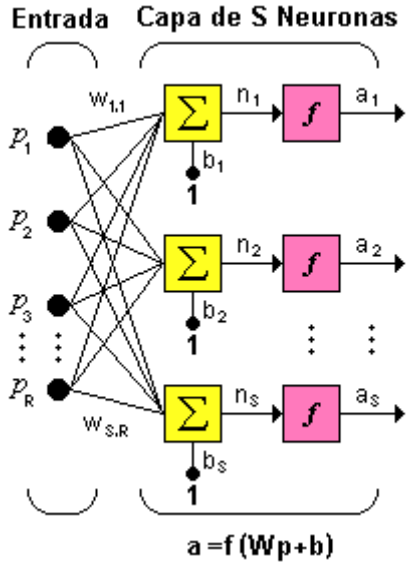

Figura 4.15:Capa de *S* neuronas

La capa incluye la matriz de pesos, los sumadores, el vector de ganancias, la función de transferencia y el vector de salida. Esta misma capa se observa en notación abreviada en la figura 4.16

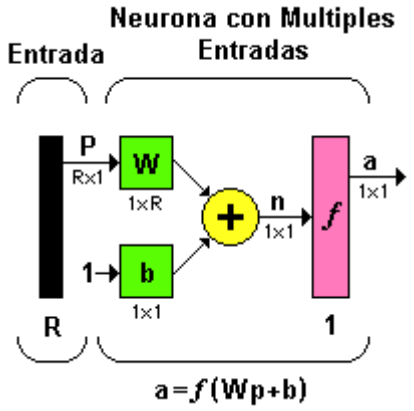

Figura 4.16:Capa de S neuronas con notación abreviada

En la figura 4.16 se han dispuesto los símbolos de las variables de tal manera que describan las características de cada una de ellas, por ejemplo la entrada a la red es el vector p cuya longitud R aparece en su parte inferior, W es la matriz de pesos con dimensiones SxR expresadas debajo del símbolo que la representa dentro de la red, a y b son vectores de

longitud S el cual, como se ha dicho anteriormente representa el número de neuronas de la red.

Ahora, si se considera una red con varias capas, o red multicapa, cada capa tendrá su propia matriz de peso W, su propio vector de ganancias b, un vector de entradas netas n, y un vector de salida a. La versión completa y la versión en notación abreviada de una red de tres capas, pueden ser visualizadas en las figuras 4.17 y 4.18, respectivamente.

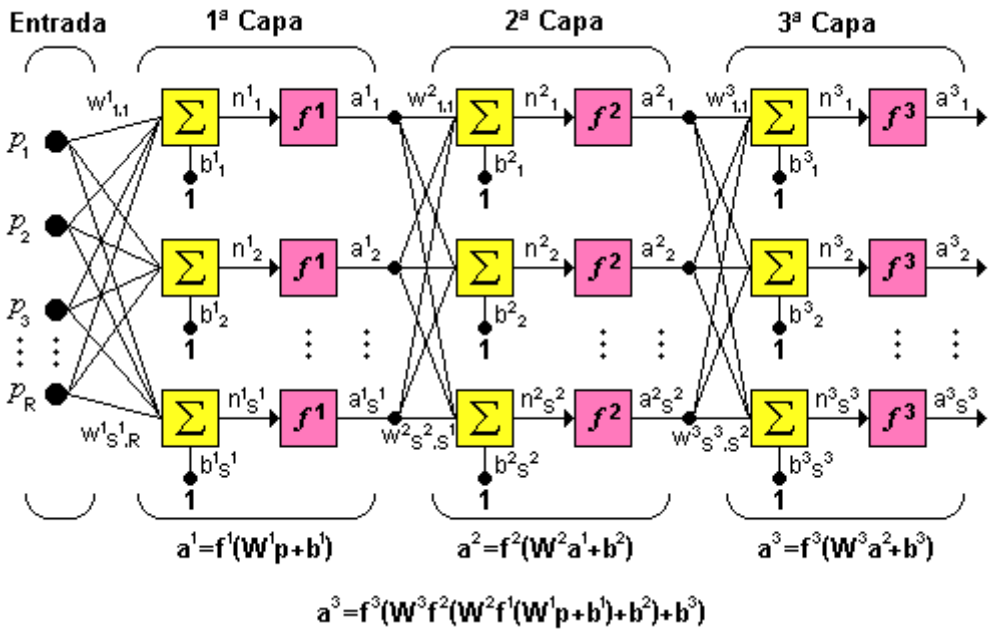

Figura 4.17:Red de tres capas

Para esta red se tienen R entradas, S^1 neuronas en la primera capa, S^2 neuronas en la segunda capa, las cuales pueden ser diferentes; las salidas de las capas 1 y 2 son las entradas a las capas 2 y 3 respectivamente, así la capa 2 puede ser vista como una red de una capa con $R=S^1$ entradas, $S^1=S^2$ neuronas y una matriz de pesos W^2 de dimensiones S^1xS^2

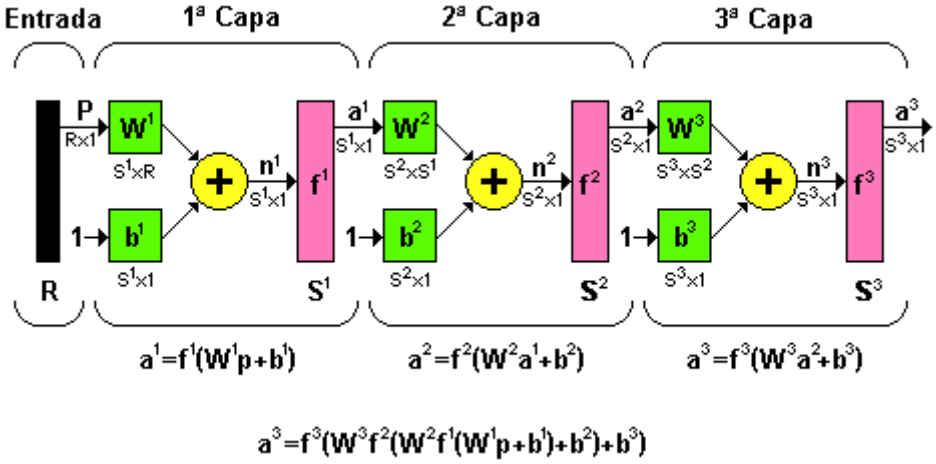

Figura 4.18:Red de tres capas con notación abreviada

Las redes multicapa son más poderosas que las redes de una sola capa, por ejemplo, una red de dos capas que tenga una función sigmoidal en la primera capa y una función lineal en la segunda, puede ser entrenada para aproximar muchas funciones de forma aceptable, una red de una sola capa no podría hacer esto como se verá en capítulos posteriores.

Un tipo de redes, un poco diferente a las que se han estudiado hasta el momento, son las redes recurrentes, estas contienen una realimentación hacia atrás o retroalimentación, es decir algunas de sus salidas son conectadas a sus entradas. Un tipo de red recurrente de tiempo discreto es mostrado en la figura 4.19.

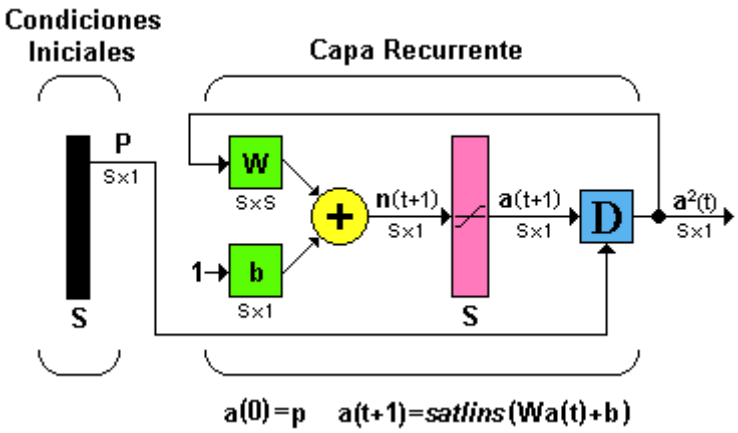

Figura 4.19:Redes Recurrentes

Para este tipo particular de red el vector *p* suple las condiciones iniciales (*a*(0)= *p*), y la salida está determinada por:

(Ec 4-8) $$a(1) = satlins(Wa(0) + b), \quad a(2) = satlins(Wa(1) + b)$$

Donde a(1) y a(2), corresponden a la salida de la red para el primer y segundo intervalo de tiempo, respectivamente. La red alcanzará su estado estable cuando la salida para un instante de tiempo sea la misma salida del instante de tiempo anterior.

Las redes recurrentes son potencialmente más poderosas que las redes con realimentación hacia delante. En este tipo de redes se introducen también dos nuevos conceptos, el bloque de retardo de la figura 4.20 y el bloque integrador de la figura 4.21

- Retardo

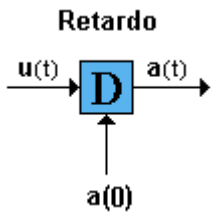

Figura 4.20:Bloque de retardo

(Ec 4-9) $$a(t) = u(t-1)$$

La salida del bloque de retardo es el valor de entrada retrasado en un paso de tiempo, este bloque requiere que la salida sea inicializada con el valor a(0) para el tiempo t=0; a(0) se convierte en la salida de la red para el instante de tiempo inicial.

- Integrador

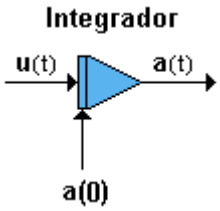

Figura 4.21:Bloque integrador

La salida del integrador es calculada de acuerdo a la expresión

$$a(t) = \int_0^t u(\tau)d\tau + a(0) \qquad \text{(Ec 4-10)}$$

En general las redes neuronales se pueden clasificar de diversas maneras, según su topología, forma de aprendizaje (supervisado o no supervisado), tipos de funciones de activación, valores de entrada (binarios o continuos); un resumen de esta clasificación se observa en la figura 4.22

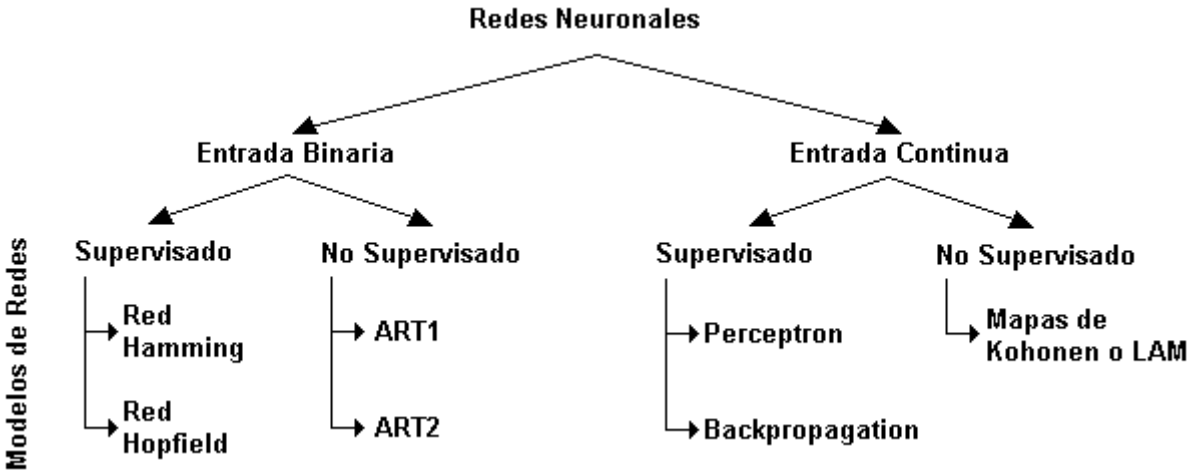

Figura 4.22:Clasificación de las Redes Neuronales

4.4 Principales tipos de redes neuronales

4.4.1 Perceptrón

4.4.1.1 Antecedentes:

La primera red neuronal conocida, fue desarrollada en 1943 por Warren McCulloch y Walter Pitts; esta consistía en una suma de las señales de entrada, multiplicadas por unos valores de pesos escogidos aleatoriamente. La entrada es comparada con un patrón preestablecido para determinar la salida de la red. Si en la comparación, la suma de las entradas multiplicadas por los pesos es mayor o igual que el patrón preestablecido la salida de la red es uno (1), en caso contrario la salida es cero (0). Al inicio del desarrollo de los sistemas de inteligencia artificial, se

encontró gran similitud entre su comportamiento y el de los sistemas biológicos y en principio se creyó que este modelo podía computar cualquier función aritmética o lógica.

La red tipo Perceptrón fue inventada por el psicólogo Frank Rosenblatt en el año 1957. Su intención era ilustrar algunas propiedades fundamentales de los sistemas inteligentes en general, sin entrar en mayores detalles con respecto a condiciones específicas y desconocidas para organismos biológicos concretos. Rosenblatt creía que la conectividad existente en las redes biológicas tiene un elevado porcentaje de aleatoriedad, por lo que se oponía al análisis de McCulloch Pitts en el cual se empleaba lógica simbólica para analizar estructuras bastante idealizadas. Rosenblatt opinaba que la herramienta de análisis más apropiada era la teoría de probabilidades, y esto lo llevó a una teoría de *separabilidad estadística* que utilizaba para caracterizar las propiedades más visibles de estas redes de interconexión ligeramente aleatorias.

El primer modelo de Perceptrón fue desarrollado en un ambiente biológico imitando el funcionamiento del ojo humano, el fotoperceptrón como se le llamo era un dispositivo que respondía a señales ópticas; como se muestra en el figura 4.23 la luz incide en los puntos sensibles (S) de la estructura de la retina, cada punto S responde en forma todo-nada a la luz entrante, los impulsos generados por los puntos S se transmiten a las unidades de asociación (A) de la capa de asociación; cada unidad A está conectada a un conjunto aleatorio de puntos S, denominados conjunto fuente de la unidad A, y las conexiones pueden ser tanto excitatorias como inhibitorias. Las conexiones tienen los valores posibles +1, -1 y 0, cuando aparece un conjunto de estímulos en la retina, una unidad A se activa si la suma de sus entradas sobrepasa algún valor umbral; si la unidad esta activada, A produce una salida que se envía a la siguiente capa de unidades.

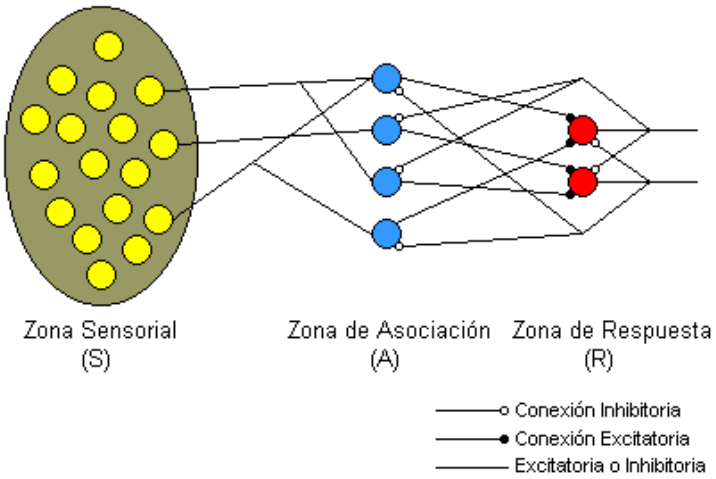

Figura 4.23:Modelo del Fotoperceptrón de Rosenblatt

De forma similar, las unidades A están conectadas a unidades de respuesta (R) dentro de la capa de respuesta y la conectividad vuelve a ser aleatorio entre capas, pero se añaden conexiones inhibitorias de realimentación procedentes de la capa de respuesta y que llegan a la capa de asociación, también hay conexiones inhibitorias entre las unidades R. Todo el esquema de conexiones se describe en forma general en un diagrama de Venn, para un Perceptrón sencillo con dos unidades de respuesta como el de la figura 4.24

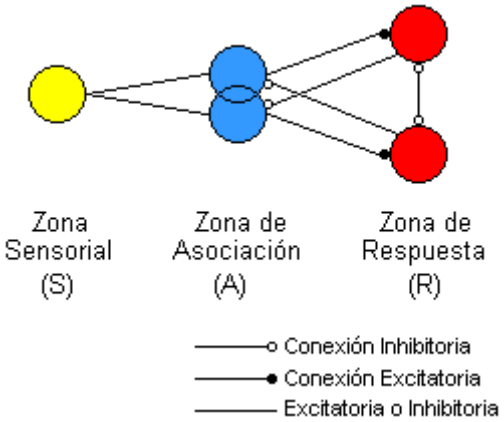

Figura 4.24:Esquema de conexiones de un Perceptrón sencillo

El Perceptrón era inicialmente un dispositivo de aprendizaje, en su configuración inicial no estaba en capacidad de distinguir patrones de entrada muy complejos, sin embargo mediante un proceso de aprendizaje era capaz de adquirir esta capacidad. En esencia, el entrenamiento implicaba un proceso de refuerzo mediante el cual la salida de las unidades A se incrementaba o se decrementaba dependiendo de si las unidades A contribuían o no a las respuestas correctas del Perceptrón para una entrada dada. Se aplicaba una entrada a la retina, y el estímulo se propagaba a través de las capas hasta que se activase una unidad de respuesta. Si se había activado la unidad de respuesta correcta, se incrementaba la salida de las unidades A que hubieran contribuido. Si se activaba una unidad R incorrecta, se hacía disminuir la salida de las unidades A que hubiesen contribuido.

Mediante estas investigaciones se pudo demostrar que el Perceptrón era capaz de clasificar patrones correctamente, en lo que Rosenblatt denominaba un entorno diferenciado, en el cual cada clase estaba formada por patrones similares. El Perceptrón también era capaz de responder de manera congruente frente a patrones aleatorios, pero su precisión iba disminuyendo a medida que aumentaba el número de patrones que intentaba aprender.

En 1969 Marvin Minsky y Seymour Papert publicaron su libro: "Perceptrons: An introduction to Computational Geometry" [114], el cual para muchos significó el final de las redes neuronales. En el se presentaba un análisis detallado del Perceptrón, en términos de sus capacidades y limitaciones, en especial en cuanto a las restricciones que existen para los problemas que una red tipo Perceptrón puede resolver; la mayor desventaja de este tipo de redes es su incapacidad para solucionar problemas que no sean linealmente separables.

Minsky y Papert se apartaban de la aproximación probabilística de Rosenblatt y volvían a las ideas de cálculo de predicados en el análisis del Perceptrón. Su idea de Perceptrón aparece en la figura 4.25

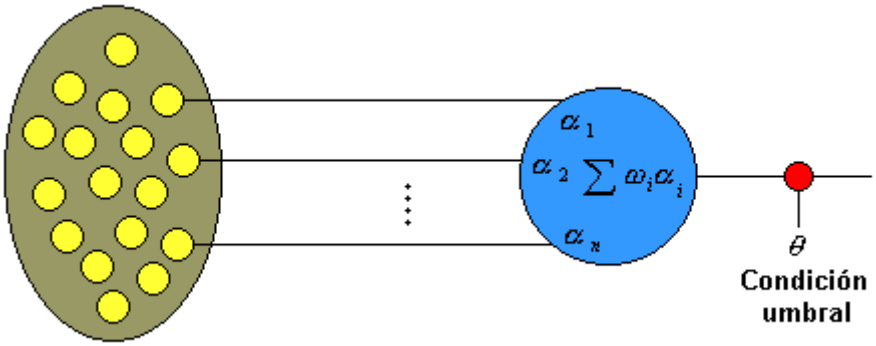

Figura 4.25: Perceptrón según Minsky y Papera

La estructura de un Perceptrón sencillo es similar a la del elemento general de procesamiento que se muestra en la figura 4.25; en la que se observa la adición de una condición umbral en la salida. Si la entrada neta, a esta condición es mayor que el valor umbral, la salida de la red es 1, en caso contrario es 0.

La función de salida de la red en la figura 4.25 es llamada función umbral o función de transferencia

(Ec 4-11) $$f(salida) = \begin{cases} 1 \text{ si salida} \geq \theta \\ 0 \text{ si salida} < \theta \end{cases}$$

A pesar de esta limitación, el Perceptrón es aún hoy una red de gran importancia, pues con base en su estructura se han desarrollado otros modelos de red neuronal como la red Adaline y las redes multicapa.

4.4.1.2 Estructura de la red:

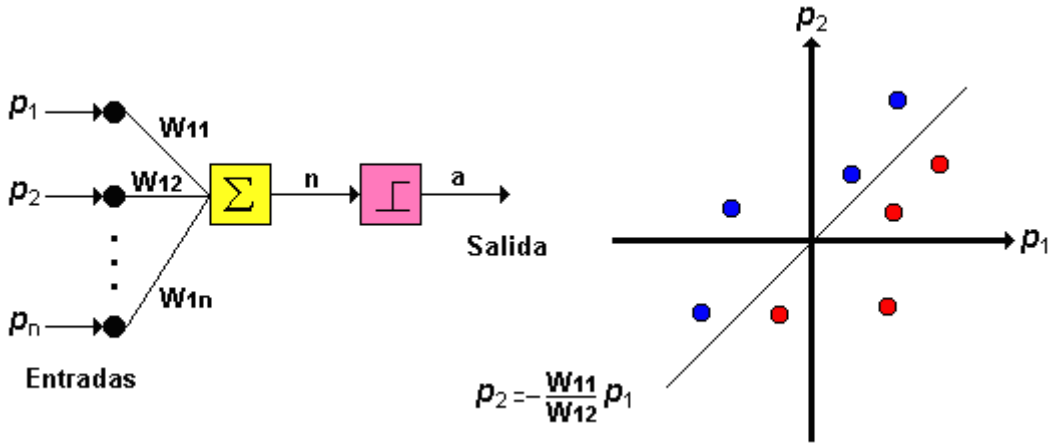

Figura 4.26:Perceptrón

La única neurona de salida del Perceptrón realiza la suma ponderada de las entradas, resta el umbral y pasa el resultado a una función de transferencia de tipo escalón. La regla de decisión es responder +1 si el patrón presentado pertenece a la clase A, o –1 si el patrón pertenece a la clase B (figura 4.26), la salida depende de la entrada neta (n = suma de las entradas p_i ponderadas).

La red tipo Perceptrón emplea principalmente dos funciones de transferencia, *hardlim* con salidas 1, 0 o *hardlims* con salidas 1, -1; su uso depende del valor de salida que se espera para la red, es decir si la salida de la red es unipolar o bipolar; sin embargo la función *hardlims* es preferida sobre la *hardlim*, ya que el tener un cero multiplicando algunas de los valores resultantes del producto de las entradas por el vector de pesos, ocasiona que estos no se actualicen y que el aprendizaje sea más lento.

Una técnica utilizada para analizar el comportamiento de redes como el Perceptrón es presentar en un mapa las regiones de decisión creadas en el espacio multidimensional de entradas de la red, en estas regiones se visualiza qué patrones pertenecen a una clase y cuáles a otra, el Perceptrón separa las regiones por un hiperplano cuya ecuación queda determinada por los pesos de las conexiones y el valor umbral de la función de activación de la neurona, en este caso los valores de los pesos pueden fijarse o adaptarse empleando diferentes algoritmos de entrenamiento.

Para ilustrar el proceso computacional del Perceptrón consideremos la matriz de pesos en forma general.

(Ec 4-12) $$W = \begin{bmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,R} \\ W_{2,1} & W_{2,2} & \dots & W_{2,R} \\ W_{S,1} & W_{S,2} & \dots & W_{S,R} \end{bmatrix}$$

Los pesos para una neurona están representados por un vector compuesto de los elementos de la *i*-ésima fila de *W*

(Ec 4-13) $$w = \begin{bmatrix} w_{i,1} \\ w_{i,2} \\ . \\ . \\ w_{i,R} \end{bmatrix}$$

De esta forma y empleando la función de transferencia *hardlim* la salida de la neurona *i* de la capa de salida

(Ec 4-14) $$a_i = \text{hardlim}(n_i) = \text{hardlim}(w_i^T p_i)$$

El Perceptrón, al constar de una sola capa de entrada y otra de salida con una única neurona, tiene una capacidad de representación bastante limitada, este modelo sólo es capaz de discriminar patrones muy sencillos, patrones linealmente separables, el caso más conocido es la imposibilidad del Perceptrón de representar la función OR EXCLUSIVA.

4.4.2 Adaline

4.4.2.1 Antecedentes:

Al mismo tiempo que Frank Rosenblatt trabajaba en el modelo del Perceptrón Bernard Widrow y su estudiante Marcian Hoff introdujeron el modelo de la red Adaline y su regla de aprendizaje llamada algoritmo LMS (Least Mean Square).

La red Adaline es similar al Perceptrón, excepto en su función de transferencia, la cual es una función de tipo lineal en lugar de un limitador fuerte como en el caso del Perceptrón. La red Adaline presenta la misma limitación del Perceptrón en cuanto al tipo de problemas que pueden resolver, ambas redes pueden solo resolver problemas linealmente separables, sin embargo el algoritmo LMS es más potente que la regla de aprendizaje del Perceptrón ya que

minimiza el error medio cuadrático, la regla sirvió de inspiración para el desarrollo de otros algoritmos, este es el gran aporte de esta red.

El término Adaline es una sigla, sin embargo su significado cambió ligeramente a finales de los años sesenta cuando decayó el estudio de las redes neuronales, inicialmente se llamaba Adaptive LInear NEuron (Neurona Lineal Adaptiva), para pasar después a ser Adaptive LInear Element (Elemento Lineal Adaptivo), este cambio se debió a que la Adaline es un dispositivo que consta de un único elemento de procesamiento, como tal no es técnicamente una red neuronal.

El elemento de procesamiento realiza la suma de los productos de los vectores de entrada y de pesos, y aplica una función de salida para obtener un único valor de salida, el cual debido a su función de transferencia lineal será +1 si la sumatoria es positiva o –1 si la salida de la sumatoria es negativa. En términos generales la salida de la red está dada por

(Ec 4-15) $a = W^T p$

En este caso, la salida es la función unidad al igual que la función de activación; el uso de la función identidad como función de salida y como función de activación significa que la salida es igual a la activación, que es la misma entrada neta al elemento.

El Adaline es Adaptativo en el sentido de que existe un procedimiento bien definido para modificar los pesos con objeto de hacer posible que el dispositivo proporcione el valor de salida correcto para la entrada dada; el significado de correcto para efectos del valor de salida depende de la función de tratamiento de señales que esté siendo llevada a cabo por el dispositivo. El Adaline es Lineal porque la salida es una función lineal sencilla de los valores de la entrada. Es una Neurona tan solo en el sentido (muy limitado) del PE. También se podría decir que el Adaline es un Elemento Lineal, evitando por completo la definición como Neurona.

4.4.2.2 Estructura de la red:

La estructura general de la red tipo Adaline puede visualizarse en la figura 4.27

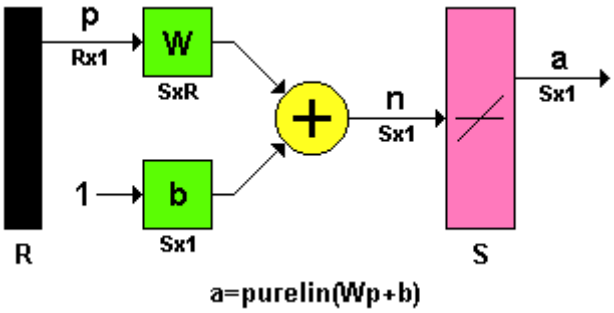

Figura 4.27:Estructura de una red Adaline

La salida de la red está dada por:

(Ec 4-16) $a = \text{purelin}(W_p + b) = W_p + b$

Para una red Adaline de una sola neurona con dos entradas el diagrama corresponde a la figura 4.28

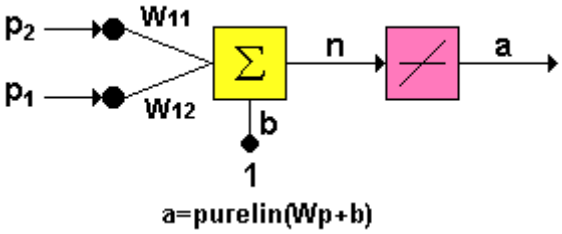

Figura 4.28:Adaline de una neurona y dos entradas

En similitud con el Perceptrón, el límite de la característica de decisión para la red Adaline se presenta cuando n = 0, por lo tanto:

(Ec 4-17) $W^T p + b = 0$

especifica la línea que separa en dos regiones el espacio de entrada, como se muestra en la figura 4.29

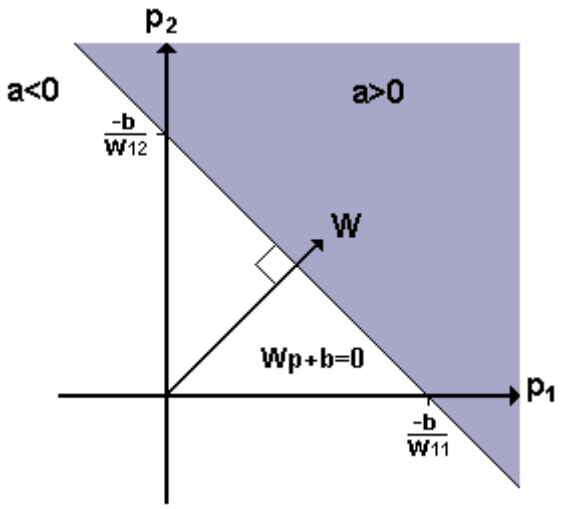

Figura 4.29:Característica de decisión de una red tipo Adaline

La salida de la neurona es mayor que cero en el área gris, en el área blanca la salida es menor que cero. Como se mencionó anteriormente, la red Adaline puede clasificar correctamente patrones linealmente separables en dos categorías.

4.4.3 Backpropagation

4.4.3.1 Antecedentes:

La regla de aprendizaje del Perceptrón de Rosenblatt y el algoritmo LMS de Widrow y Hoff fueron diseñados para entrenar redes de una sola capa. Como se discutió anteriormente, estas redes tienen la desventaja que solo pueden resolver problemas linealmente separables, fue esto lo que llevo al surgimiento de las redes multicapa para sobrepasar esta dificultad en las redes hasta entonces conocidas.

El primer algoritmo de entrenamiento para redes multicapa fue desarrollado por Paul Werbos en 1974, este se desarrolló en un contexto general, para cualquier tipo de redes, siendo las redes neuronales una aplicación especial, razón por la cual el algoritmo no fue aceptado dentro de la comunidad de desarrolladores de redes neuronales. Fue solo hasta mediados de los años 80 cuando el algoritmo Backpropagation o algoritmo de propagación inversa fue redescubierto

al mismo tiempo por varios investigadores, David Rumelhart, Geoffrey Hinton y Ronal Williams, David Parker y Yann Le Cun. El algoritmo se popularizó cuando fue incluido en el libro "Parallel Distributed Processing Group" por los sicólogos David Rumelhart y James McClelland. La publicación de este libro trajo consigo un auge en las investigaciones con redes neuronales, siendo la Backpropagation una de las redes más ampliamente empleadas, aun en nuestros días.

Uno de los grandes avances logrados con la Backpropagation es que esta red aprovecha la naturaleza paralela de las redes neuronales para reducir el tiempo requerido por un procesador secuencial para determinar la correspondencia entre unos patrones dados. Además el tiempo de desarrollo de cualquier sistema que se este tratando de analizar se puede reducir como consecuencia de que la red puede aprender el algoritmo correcto sin que alguien tenga que deducir por anticipado el algoritmo en cuestión.

La mayoría de los sistemas actuales de cómputo se han diseñado para llevar a cabo funciones matemáticas y lógicas a una velocidad que resulta asombrosamente alta para el ser humano. Sin embargo la destreza matemática no es lo que se necesita para solucionar problemas de reconocimiento de patrones en entornos ruidosos, característica que incluso dentro de un espacio de entrada relativamente pequeño, puede llegar a consumir mucho tiempo. El problema es la naturaleza secuencial del propio computador; el ciclo tomar – ejecutar de la naturaleza Von Neumann solo permite que la máquina realice una operación a la vez. En la mayoría de los casos, el tiempo que necesita la máquina para llevar a cabo cada instrucción es tan breve (típicamente una millonésima de segundo) que el tiempo necesario para un programa, así sea muy grande, es insignificante para los usuarios. Sin embargo, para aquellas aplicaciones que deban explorar un gran espacio de entrada o que intentan correlacionar todas las permutaciones posibles de un conjunto de patrones muy complejo, el tiempo de computación necesario se hace bastante grande.

Lo que se necesita es un nuevo sistema de procesamiento que sea capaz de examinar todos los patrones en paralelo. Idealmente ese sistema no tendría que ser programado explícitamente, lo que haría es adaptarse a sí mismo para aprender la relación entre un conjunto de patrones dado como ejemplo y ser capaz de aplicar la misma relación a nuevos patrones de entrada. Este sistema debe estar en capacidad de concentrarse en las características de una entrada arbitraria que se asemeje a otros patrones vistos previamente, sin que ninguna señal de ruido lo afecte. Este sistema fue el gran aporte de la red de propagación inversa, Backpropagation.

La Backpropagation es un tipo de red de aprendizaje supervisado, que emplea un ciclo propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo las neuronas de la capa oculta solo reciben una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Basándose en la señal de error percibida, se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento.

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer, para la cual han sido entrenadas.

Varias investigaciones han demostrado que, durante el proceso de entrenamiento, la red Backpropagation tiende a desarrollar relaciones internas entre neuronas con el fin de organizar los datos de entrenamiento en clases. Esta tendencia se puede extrapolar, para llegar a la hipótesis consistente en que todas las unidades de la capa oculta de una Backpropagation son asociadas de alguna manera a características específicas del patrón de entrada como consecuencia del entrenamiento. Lo que sea o no exactamente la asociación puede no resultar evidente para el observador humano, lo importante es que la red ha encontrado una representación interna que le permite generar las salidas deseadas cuando se le dan las entradas, en el proceso de entrenamiento. Esta misma representación interna se puede aplicar a entradas que la red no haya visto antes, y la red clasificará estas entradas según las características que compartan con los ejemplos de entrenamiento.

4.4.3.2 Estructura de la Red:

La estructura típica de una red multicapa se observa en la figura 4.30

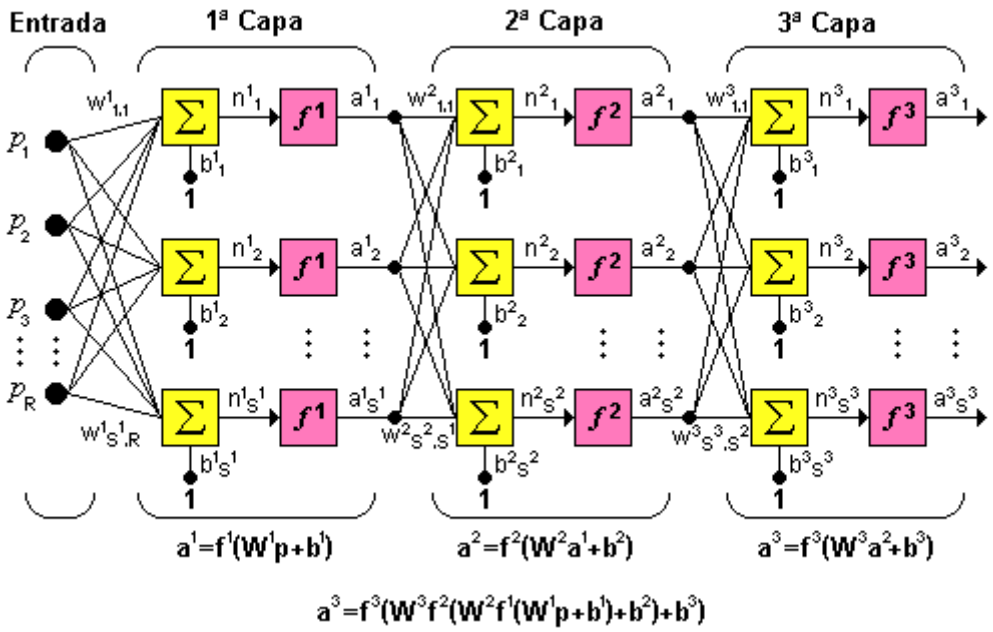

Figura 4.30:Red de tres capas

Puede notarse que esta red de tres capas equivale a tener tres redes tipo Perceptrón en cascada; la salida de la primera red, es la entrada a la segunda y la salida de la segunda red es la entrada a la tercera. Cada capa puede tener diferente número de neuronas, e incluso distinta función de transferencia.

En la figura 4.30, W^1 representa la matriz de pesos para la primera capa, W^2 los pesos de la segunda y así similarmente para todas las capas que incluya una red. Para identificar la estructura de una red multicapa, se empleará una notación abreviada, donde el número de entradas va seguido del número de neuronas en cada capa:

(Ec 4-18) $R : S^1 : S^2 : S^3$

Donde S representa el número de neuronas y el exponente representa la capa a la cual la neurona corresponde.

La notación de la figura 4.30 es bastante clara cuando se desea conocer la estructura detallada de la red, e identificar cada una de las conexiones, pero cuando la red es muy grande, el proceso de conexión se torna muy complejo y es bastante útil utilizar el esquema de la figura 4.31

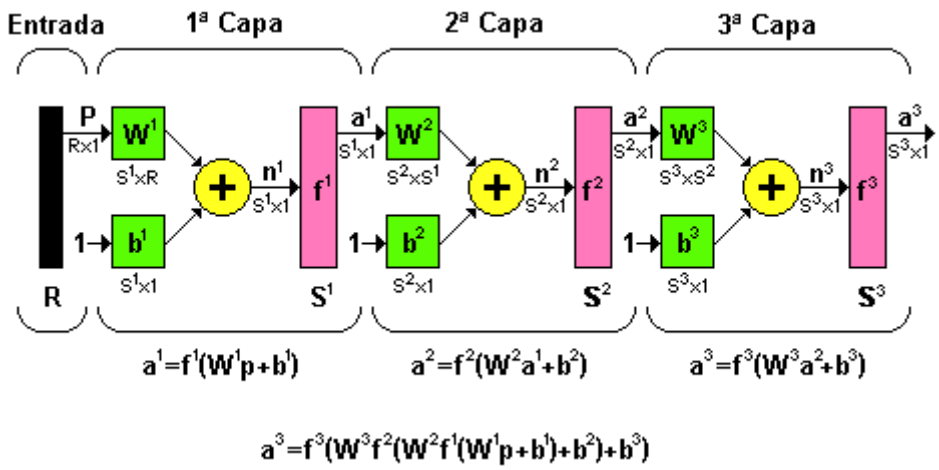

Figura 4.31:Notación compacta de una red de tres capas

4.4.3.3 Regla de Aprendizaje

El algoritmo Backpropagation para redes multicapa es una generalización del algoritmo LMS, ambos algoritmos realizan su labor de actualización de pesos y ganancias con base en el error medio cuadrático. La red Backpropagation trabaja bajo aprendizaje supervisado y por tanto necesita un set de entrenamiento que le describa cada salida y su valor de salida esperado de la siguiente forma:

(Ec 4-19) $\{p_1, t_1\}, \{p_2, t_2\}, \ldots, \{p_o, t_o\}$

Donde p_Q es una entrada a la red y t_Q es la correspondiente salida deseada para el patrón q-ésimo. El algoritmo debe ajustar los parámetros de la red para minimizar el error medio cuadrático.

$$a_i = \text{hardlim}(n_i) = \text{hardlim}(w_i^T p_i)$$

El entrenamiento de una red neuronal multicapa se realiza mediante un proceso de aprendizaje, para realizar este proceso se debe inicialmente tener definida la topología de la red esto es: número de neuronas en la capa de entrada el cual depende del número de componentes del vector de entrada, cantidad de capas ocultas y número de neuronas de cada una de ellas, número de neuronas en la capa de la salida el cual depende del número de componentes del vector de salida o patrones objetivo y funciones de transferencia requeridas en cada capa, con base en la topología escogida se asignan valores iniciales a cada uno de los parámetros que conforma la red.

Es importante recalcar que no existe una técnica para determinar el número de capas ocultas, ni el número de neuronas que debe contener cada una de ellas para un problema especifico, esta elección es determinada por la experiencia del diseñador, el cual debe cumplir con las limitaciones de tipo computacional.

Cada patrón de entrenamiento se propaga a través de la red y sus parámetros para producir una respuesta en la capa de salida, la cual se compara con los patrones objetivo o salidas deseadas para calcular el error en el aprendizaje, este error marca el camino mas adecuado para la actualización de los pesos y ganancias que al final del entrenamiento producirán una respuesta satisfactoria a todos los patrones de entrenamiento, esto se logra minimizando el error medio cuadrático en cada iteración del proceso de aprendizaje.

La deducción matemática de este procedimiento se realizará para una red con una capa de entrada, una capa oculta y una capa de salida y luego se generalizará para redes que tengan más de una capa oculta.

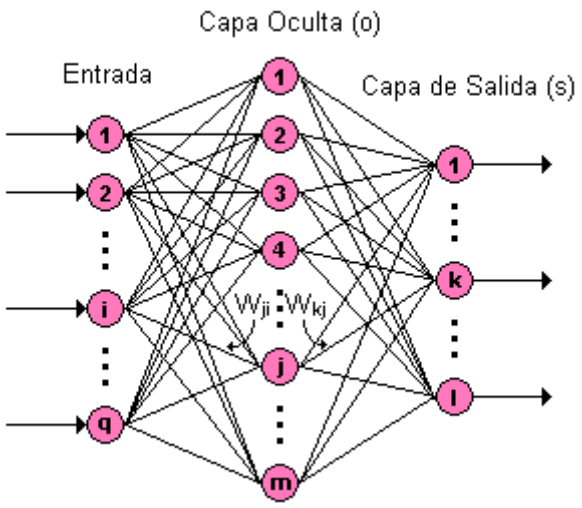

Figura 4.32:Disposición de una red sencilla de 3 capas

Es importante aclarar que en la figura 4.32:

q: Equivale al número de componentes el vector de entrada.
m: Número de neuronas de la capa oculta
l: Número de neuronas de la capa de salida

Para iniciar el entrenamiento se le presenta a la red un patrón de entrenamiento, el cual tiene *q* componentes como se describe en la ecuación 4-20

(Ec 4-20) $$p = \begin{bmatrix} p_1 \\ p_2 \\ . \\ . \\ p_i \\ . \\ . \\ p_q \end{bmatrix}$$

Cuando se le presenta a la red una patrón de entrenamiento, este se propaga a través de las conexiones existentes produciendo una entrada neta *n* en cada una las neuronas de la siguiente capa, la entrada neta a la neurona *j* de la siguiente capa debido a la presencia de un patrón de entrenamiento en la entrada esta dada por la ecuación 4-21, nótese que la entrada neta es el valor justo antes de pasar por la función de transferencia

(Ec 4-21) $$n_j^o = \left(\sum_{i=1}^{q} W_{ji}^o p_i + b_j^o \right)$$

W^o_{ji}: Peso que une la componente *i* de la entrada con la neurona *j* de la capa oculta
p_i: *Componente i* del vector *p* que contiene el patrón de entrenamiento de *q* componentes
b^o_j: Ganancia de la neurona *j* de la capa oculta
Donde el superíndice (^{o}) representa la capa a la que pertenece cada parámetro, es este caso la capa oculta.
Cada una de las neuronas de la capa oculta tiene como salida a^o_j que esta dada por la ecuación 4-22

(Ec 4-22) $$a_j^o = f^o\left(\sum_{i=1}^{q} W_{ji}^o p_i + b_j^o\right)$$

f^o: Función de transferencia de las neuronas de la capa oculta

Las salidas a^o_j de las neuronas de la capa oculta (de *l* componentes) son las entradas a los pesos de conexión de la capa de salida, este comportamiento esta descrito por la ecuación 4-23

(Ec 4-23) $$n_k^s = \left(\sum_{i=1}^{m} W_{kj}^s a_j^o + b_k^s\right)$$

W^s_{kj}: Peso que une la neurona *j* de la capa oculta con la neurona *k* de la capa de salida, la cual cuenta con *s* neuronas

a^o_j: Salida de la neurona *j* de la capa oculta, la cual cuenta con *m* neuronas.

b^s_k: Ganancia de la neurona *k* de la capa de salida.

n^s_k: Entrada neta a la neurona *k* de la capa de salida

La red produce una salida final descrita por la ecuación 4-24

(Ec 4-24) $$a_k^s = f^s\left(n_k^s\right)$$

f^s: Función de transferencia de las neuronas de la capa de salida

Reemplazando 4-23 en 4-24 se obtiene la salida de la red en función de la entrada neta y de los pesos de conexión con la última capa oculta

(Ec 4-25) $$a_k^s = f^s\left(\sum_{i=1}^{m} W_{kj}^s a_j^o + b_k^s\right)$$

La salida de la red de cada neurona a^s_k se compara con la salida deseada t_k para calcular el error en cada unidad de salida 4-26

(Ec 4-26) $$\delta_k = \left(t_k - a_k^s\right)$$

El error debido a cada patrón *p* propagado esta dado por 4-27

(Ec 4-27) $$ep^2 = \frac{1}{2}\sum_{k=1}^{s}(\delta_k)^2$$

ep^2: Error medio cuadrático para cada patrón de entrada *p*

δ_k : Error en la neurona *k* de la capa de salida con *l* neuronas

Este proceso se repite para el número total de patrones de entrenamiento (*r*), para un proceso de aprendizaje exitoso el objetivo del algoritmo es actualizar todos los pesos y ganancias de la red minimizando el error medio cuadrático total descrito en 4-28

(Ec 4-28) $$e^2 = \sum_{p=1}^{r} ep^2$$

e^2: Error total en el proceso de aprendizaje en una iteración luego de haber presentado a la red los *r* patrones de entrenamiento

El error que genera una red neuronal en función de sus pesos, genera un espacio de n dimensiones, donde n es el número de pesos de conexión de la red, al evaluar el gradiente del error en un punto de esta superficie se obtendrá la dirección en la cual la función del error tendrá un mayor crecimiento, como el objetivo del proceso de aprendizaje es minimizar el error debe tomarse la dirección negativa del gradiente para obtener el mayor decremento del error y de esta forma su minimización, condición requerida para realizar la actualización de la matriz de pesos en el algoritmo Backpropagation:

(Ec 4-29) $$W_{k+1} = W_k - \alpha \nabla ep^2$$

El gradiente negativo de ep^2 se denotara como $-\nabla ep^2$ y se calcula como la derivada del error respecto a todos los pesos de la red

En la capa de salida el gradiente negativo del error con respecto a los pesos es:

(Ec 4-30) $$-\frac{\partial ep^2}{\partial W_{kj}^s} = -\frac{\partial}{\partial W_{kj}^s}\left(\frac{1}{2}\sum_{k=1}^{l}\left(t_k - a_k^s\right)^2\right) = \left(t_k - a_k^s\right) \times \frac{\partial a_k^s}{\partial W_{kj}^s}$$

$-\frac{\partial ep^2}{\partial W_{kj}^s}$: Componente del gradiente $-\nabla ep^2$ respecto al peso de la conexión de la neurona de la capa de salida y la neurona j de la capa oculta W_{kj}^s

$\frac{\partial a_k^s}{\partial W_{kj}^s}$: Derivada de la salida de la neurona *k* de la capa de salida respecto, al peso W^s_{kj}

Para calcular $\frac{\partial a_k^s}{\partial W_{kj}^s}$ se debe utilizar la regla de la cadena, pues el error no es una función

explícita de los pesos de la red, de la ecuación 4-24 puede verse que la salida de la red a^s_k esta explícitamente en función de n^s_k y de la ecuación 4-23 puede verse que n^s_k esta explícitamente en función de W^s_{kj}, considerando esto se genera la ecuación 4-30

(Ec 4-31) $$\frac{\partial a_k^s}{\partial W_{kj}^s} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s}$$

Tomando la ecuación 4-31 y reemplazándola en la ecuación 4-30 se obtiene,

(Ec 4-32) $$-\frac{\partial ep^2}{\partial W_{kj}^s} = \left(t_k - a_k^s\right) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s}$$

$\frac{\partial n_k^s}{\partial W_{kj}^s}$: Derivada de la entrada neta a la neurona *k* de la capa de salida respecto a los pesos de la conexión entre las neuronas de la capa oculta y la capa de salida

$\frac{\partial a_k^s}{\partial n_k^s}$: Derivada de la salida de la neurona *k* de la capa de salida respecto a su entrada neta.

Reemplazando en la ecuación 4-32 las derivadas de las ecuaciones 4-23 y 4-24 se obtiene

(Ec 4-33) $$-\frac{\partial ep^2}{\partial W_{kj}^s} = \left(t_k - a_k^s\right) \times f'^s\left(n_k^s\right) \times a_j^o$$

Como se observa en la ecuación 4-33 las funciones de transferencia utilizadas en este tipo de red deben ser continuas para que su derivada exista en todo el intervalo, ya que el término $f'^{s}(n^{s}_{k})$ es requerido para el cálculo del error.

Las funciones de transferencia (f) más utilizadas y sus respectivas derivadas son las siguientes:

(Ec 4-34) *logsig*: $f(n) = \dfrac{1}{1+e^{-n}}$; $\mathrm{f'(n)} = f(n)(1-f(n))$; $\mathrm{f'(n)} = \mathrm{a(1-a)}$

(Ec 4-35) *tansig*: $f(n) = \dfrac{e^{n}-e^{-n}}{e^{n}+e^{-n}}$; $\mathrm{f'(n)} = 1-(f(n))^{2}$; $\mathrm{f'(n)} = (1-\mathrm{a}^{2})$

(Ec 4-36) *purelin*: $f(n) = n$; $\mathrm{f'(n)} = 1$

De la ecuación 4-33, los términos del error para las neuronas de la capa de salida están dados por la ecuación 4-37, la cual se le denomina comúnmente sensitividad de la capa de salida.

(Ec 4-37) $$\delta_{k} = (t_{k} - a^{s}_{k}) f'^{s}(n^{s}_{k})$$

Este algoritmo se denomina Backpropagation o de propagación inversa debido a que el error se propaga de manera inversa al funcionamiento normal de la red, de esta forma, el algoritmo encuentra el error en el proceso de aprendizaje desde las capas más internas hasta llegar a la entrada; con base en el cálculo de este error se actualizan los pesos y ganancias de cada capa.

Después de conocer 4-37 se procede a encontrar el error en la capa oculta el cual esta dado por:

(Ec 4-38) $$-\frac{\partial ep^{2}}{\partial W^{o}_{ji}} = -\frac{\partial}{\partial W^{o}_{ji}}\left(\frac{1}{2}\sum_{k=1}^{l}(t_{k} - a^{s}_{k})^{2}\right) = \sum_{k=1}^{l}(t_{k} - a^{s}_{k}) \times \frac{\partial a^{s}_{k}}{\partial W^{o}_{ji}}$$

Para calcular el último término de la ecuación 4-38 se debe aplicar la regla de la cadena en varias ocasiones como se observa en la ecuación 4-39 puesto que la salida de la red no es una función explícita de los pesos de la conexión entre la capa de entrada y la capa oculta

(Ec 4-39) $$\frac{\partial a_k^s}{\partial W_{ji}^o} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o}$$

Todos los términos de la ecuación 4-40 son derivados respecto a variables de las que dependan explícitamente, reemplazando 4-39 en 4-38 tenemos:

(Ec 4-40) $$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^{l} \left(t_k - a_k^s\right) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o}$$

Tomando las derivas de las ecuaciones 4-21, 4-22, 4-23, 4-24 y reemplazándolas en la ecuación 4-40 se obtiene la expresión del gradiente del error en la capa oculta

(Ec 4-41) $$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^{l} \left(t_k - a_k^s\right) \times f'^s\left(n_k^s\right) \times W_{kj}^s \times f'^o\left(n_j^0\right)$$

Reemplazando la ecuación 4-37 en la ecuación 4-41 se tiene:

(Ec 4-42) $$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^{l} \delta_k \times W_{kj}^s \times f'^o\left(n_j^0\right) \times p_i$$

Los términos del error para cada neurona de la capa oculta esta dado por la ecuación 4-43, este término también se denomina sensitividad de la capa oculta

(Ec 4-43) $$\delta_j^0 = f'^o\left(n_j^0\right) \times \sum_{k=1}^{l} \delta_k^s W_{kj}^s$$

Luego de encontrar el valor del gradiente del error se procede a actualizar los pesos de todas las capas empezando por la de salida, para la capa de salida la actualización de pesos y ganancias esta dada por 4-44 y 4-45.

(Ec 4-44) $$W_{kj}(t+1) = W_{kj}(t) - 2\alpha\delta_k^s$$

(Ec 4-45) $$b_k(t+1) = b_k(t) - 2\alpha\delta_k^s$$

α : rata de aprendizaje que varía entre 0 y 1 dependiendo de las características del problema a solucionar.

Luego de actualizar los pesos y ganancias de al capa de salida se procede a actualizar los pesos y ganancias de la capa oculta mediante las ecuaciones 4-46 y 4-47

(Ec 4-46) $W_{ji}(t+1) = W_{ji}(t) - 2\alpha\delta_j^o p_i$

(Ec 4-47) $b_j(t+1) = b_j(t) - 2\alpha\delta_j^o$

Esta deducción fue realizada para una red de tres capas, si se requiere realizar el análisis para una red con dos o más capas ocultas, las expresiones pueden derivarse de la ecuación 4-43 donde los términos que se encuentran dentro de la sumatoria pertenecen a la capa inmediatamente superior, este algoritmo es conocido como la regla Delta Generalizada desarrollada por Rumelhart D [115], la cual es una extensión de la regla delta desarrollada por Widrow [116] en 1930

Para algunos autores las sensitividades de las capas están detonadas por la letra *S*, reescribiendo las ecuaciones 4-37 y 4-43 con esta notación se obtienen las ecuaciones 4-48 y 4-49

(Ec 4-48) $S^M = -2f^M(n^M)(t-a)$

(Ec 4-49) $S^M = f^m(n^m)(W^{m+1})^T s^{m+1}$, para $\mathrm{m} = \mathrm{M}\ -1,.....,2,1.$

En la ecuación 4-48, *M* representa la última capa y S^M la sensitividad para esta capa, la ecuación 4-49 expresa el cálculo de la sensitividad capa por capa comenzando desde la última capa oculta, cada uno de estos términos involucra que el término para la sensitividad de la capa siguiente ya este calculado.

Como se ve el algoritmo Backpropagation utiliza la misma técnica de aproximación en pasos descendientes que emplea el algoritmo LMS, la única complicación está en el cálculo del gradiente, el cual es un término indispensable para realizar la propagación de la sensitividad.

En las técnicas de gradiente descendiente es conveniente avanzar por la superficie de error con incrementos pequeños de los pesos; esto se debe a que tenemos una información local de la superficie y no se sabe lo lejos o lo cerca que se está del punto mínimo, con incrementos grandes, se corre el riesgo de pasar por encima del punto mínimo, con incrementos pequeños, aunque se tarde más en llegar, se evita que esto ocurra. El elegir un incremento adecuado

influye en la velocidad de convergencia del algoritmo, esta velocidad se controla a través de la rata de aprendizaje α, la que por lo general se escoge como un número pequeño, para asegurar que la red encuentre una solución. Un valor pequeño de α significa que la red tendrá que hacer un gran número de iteraciones, si se toma un valor muy grande, los cambios en los pesos serán muy grandes, avanzando muy rápidamente por la superficie de error, con el riesgo de saltar el valor mínimo del error y estar oscilando alrededor de él, pero sin poder alcanzarlo.
Es recomendable aumentar el valor de α a medida que disminuye el error de la red durante la fase de entrenamiento, para garantizar así una rápida convergencia, teniendo la precaución de no tomar valores demasiado grandes que hagan que la red oscile alejándose demasiado del valor mínimo. Algo importante que debe tenerse en cuenta, es la posibilidad de convergencia hacia alguno de los mínimos locales que pueden existir en la superficie del error del espacio de pesos como se ve en la figura 4.33

Figura 4.33:Superficie típica de error

En el desarrollo matemático que se ha realizado para llegar al algoritmo Backpropagation, no se asegura en ningún momento que el mínimo que se encuentre sea global, una vez la red se asiente en un mínimo sea local o global cesa el aprendizaje, aunque el error siga siendo alto. En todo caso, si la solución es admisible desde el punto de vista del error, no importa si el mínimo es local o global o si se ha detenido en algún momento previo a alcanzar un verdadero mínimo.
Para ilustrar el cálculo de cada uno de los términos del algoritmo Backpropagation, este se utilizara se para aproximar la siguiente función:

(Ec 4-50) $t = \sin\frac{\pi}{4}p$ para el intervalo $-2 \le p \le 2$

La función se ha restringido al intervalo entre –2 y 2 para conservarla dentro de límites observables, como se observa en la figura 4.34

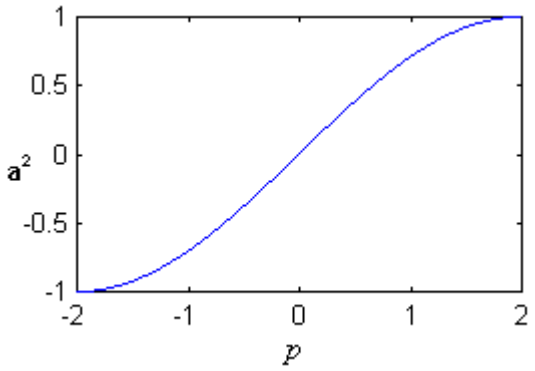

Figura 4.34:Intervalo de la función t

La configuración escogida para la red corresponde a una red 1:2:1 según la notación definida con anterioridad, es decir una entrada, dos neuronas en la capa oculta y una salida; esta estructura se visualiza en la figura 4.35

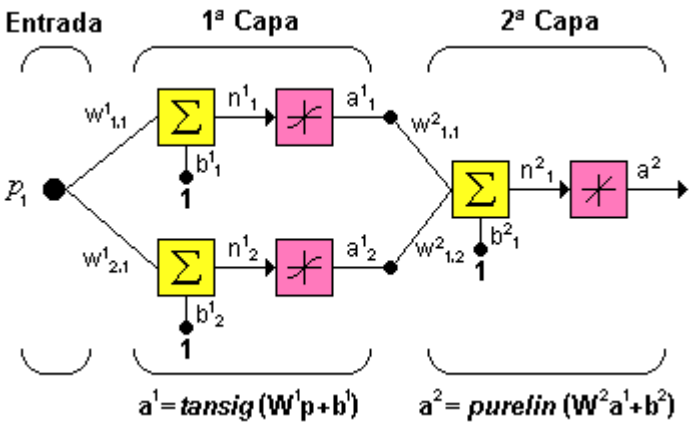

Figura 4.35:Red utilizada para aproximar la función

Como se observa la salida de la red para la primera capa está dada por

(Ec 4-51) $a^1 = \text{tansig}(W^1 p^T + b)$

Las redes tipo Backpropagation utilizan principalmente dos funciones de transferencia en la primera capa: *logsig,* cuando el rango de la función es siempre positivo y *tansig* como en este caso, cuando se le permite a la función oscilar entre valores positivos y negativos limitados en el intervalo –1, 1.

La salida de la segunda capa está determinada generalmente por la función de transferencia *purelin,* la cual reproduce exactamente el valor resultante después de la sumatoria.

(Ec 4-52) $a^2 = purelin(W^2 \times a^1 + b^2)$

Al evaluar la ecuación 4-50 en los diferentes patrones de entrenamiento, se obtienen los valores de las entradas y sus salidas asociadas, ya que como se dijo antes la red Backpropagation es una red de aprendizaje supervisado. Es importante destacar, que no es estrictamente necesario el conocimiento de la función a aproximar, basta con conocer la respuesta a una entrada dada, o un registro estadístico de salidas para modelar el comportamiento del sistema, limitando el problema a la realización de pruebas a una caja negra.

El algoritmo Backpropagation es fácil de implementar, y tiene la flexibilidad de adaptarse para aproximar cualquier función, siendo una de las redes multicapa más potentes; esta característica ha convertido a esta red en una de las más ampliamente utilizadas y ha llevado al desarrollo de nuevas técnicas que permitan su mejoramiento. Dentro de estas técnicas encontramos dos métodos heurísticos y dos métodos basados en algoritmos de optimización numérica.

4.4.3.3.1 *Red Backpropagation con momentum:*

Esta modificación está basada en la observación de la última sección de la gráfica del error medio cuadrático en el proceso de convergencia típico para una red Backpropagation; este proceso puede verse en la figura 4.36 en la cual se nota la caída brusca del error en la iteración para la cual alcanza convergencia

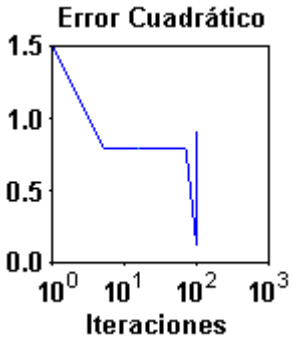

Figura 4.36:Comportamiento típico del proceso de convergencia para una red Backpropagation

Este comportamiento puede causar oscilaciones no deseadas, por lo que es conveniente suavizar esta sección de la gráfica incorporando un filtro pasa-bajo al sistema. Para ilustrar el efecto positivo del filtro en el proceso de convergencia, se analizará el siguiente filtro de primer orden:

$0 < \gamma < 1$

(Ec 4-53) $$y(k) = \gamma y(k-1) + (1-\gamma) w(k)$$

Donde *w(k)* es la entrada al filtro, *y(k)* su salida y γ es el coeficiente de momentum que está en el intervalo $0 < \gamma < 1$

El efecto del filtro puede observase en la figura 4.37, en la cual se tomó como entrada al filtro la función:

$$w(k) = 1 + sen\left(\frac{2\pi k}{16}\right)$$

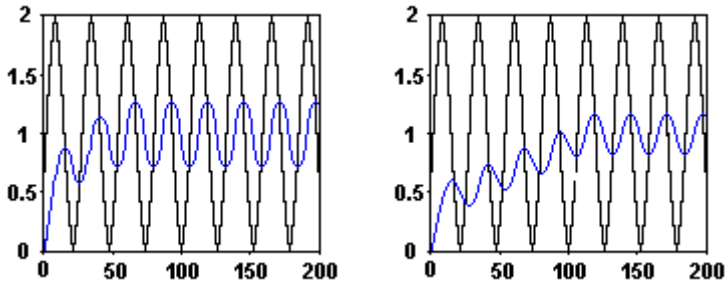

Figura 4.37:Efecto del coeficiente de momentum

El coeficiente de momentum se asumió $\gamma = 0.9$ para la gráfica de la izquierda y $\gamma = 0.8$ para la gráfica de la derecha. De esta figura puede notarse como la oscilación es menor a la salida del filtro, la oscilación se reduce a medida que γ se decrementa, el promedio de la salida del filtro es el mismo que el promedio de entrada al filtro aunque mientras γ sea incrementado la salida del filtro será más lenta.

Recordando los parámetros de actualización empleados por el algoritmo Backpropagation tradicional:

(Ec 4-54) $$\Delta W^m(k) = -\alpha s^m \left(a^{m-1}\right)^T$$

(Ec 4-55) $$\Delta b^m(k) = \alpha s^m$$

Al adicionar el filtro con momentum a este algoritmo de actualización, se obtienen las siguientes ecuaciones que representan el algoritmo Backpropagation con momentum:

(Ec 4-56) $$\Delta W^m(k) = \Delta W^m(k-1) - (1-\gamma)\alpha s^m \left(a^{m-1}\right)^T$$

(Ec 4-57) $$\Delta b^m(k) = \Delta b^m(k-1) - (1-\gamma) - \alpha s^m$$

Este algoritmo, hace que la convergencia sea estable e incluso más rápida, además permite utilizar una rata de aprendizaje alta.

La figura 4.38 referencia el comportamiento del algoritmo con momentum en el punto de convergencia:

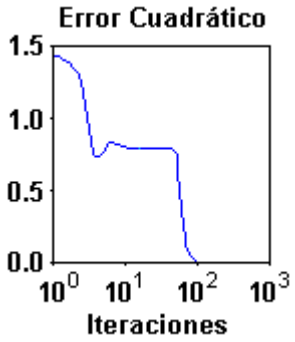

Figura 4.38:Trayectoria de convergencia con momentum

4.4.3.3.1.1 Red Backpropagation con rata de aprendizaje variable:

Se define $\nabla e^2(x)$ como la Hessiana de la función de error, donde *x* representa las variables de las cuales depende el error (pesos y ganancias), esta matriz es siempre de la forma:

$$\text{(Ec 4-58)} \quad \nabla^2 e(x) = \begin{bmatrix} \frac{\partial^2 e(x)}{\partial x_1^2} & \frac{\partial^2 e(x)}{\partial x_1 x_2} & \cdots & \frac{\partial^2 e(x)}{\partial x_1 x_n} \\ \frac{\partial^2 e(x)}{\partial x_2 x_1} & \frac{\partial^2 e(x)}{\partial x_2^2} & \cdots & \frac{\partial^2 e(x)}{\partial x_2 x_n} \\ . & . & . & . \\ . & . & . & . \\ \frac{\partial^2 e(x)}{\partial x_n x_1} & \frac{\partial^2 e(x)}{\partial x_n x_2} & \cdots & \frac{\partial^2 e(x)}{\partial x_n^2} \end{bmatrix}$$

La superficie del error medio cuadrático para redes de una sola capa es siempre una función cuadrática y la matriz Hessiana es por tanto constante, esto lleva a que la máxima rata de aprendizaje estable para el algoritmo de pasos descendientes sea el máximo valor propio de la matriz Hessiana dividido 2,HBD. Para una red multicapa la superficie del error no es una función cuadrática, su forma es diferente para diferentes regiones del espacio, la velocidad de convergencia puede incrementarse por la variación de la rata de aprendizaje en cada parte de la superficie del error, sin sobrepasar el valor máximo para aprendizaje estable definido anteriormente.

Existen varias técnicas para modificar la rata de aprendizaje; este algoritmo emplea un procedimiento mediante el cual la rata de aprendizaje varia de acuerdo al rendimiento que va presentando el algoritmo en cada punto; si el error disminuye vamos por el camino correcto y se puede ir más rápido incrementando la rata de aprendizaje, si el error aumenta, es necesario decrementar la rata de aprendizaje; el criterio de variación de α debe estar en concordancia con las siguientes reglas heurísticas:

1. Si el error cuadrático de todos los parámetros del set de entrenamiento se incrementa en un porcentaje ξ típicamente entre 1% y 5%, después de la actualización de los

pesos, esa actualización es descartada, la rata de aprendizaje se multiplica por un factor $0 < \rho < 1$, y el coeficiente de momentum es fijado en cero.

2. Si el error cuadrático se decrementa después de la actualización de los pesos, esa actualización es aceptada y la rata de aprendizaje es multiplicada por un factor $\eta > 1$. Si γ había sido previamente puesto en cero, se retorna a su valor original.
3. Si el error cuadrático se incrementa en un valor menor a ξ, los pesos actualizados son aceptados, pero la rata de aprendizaje y el coeficiente de momentum no son cambiados.

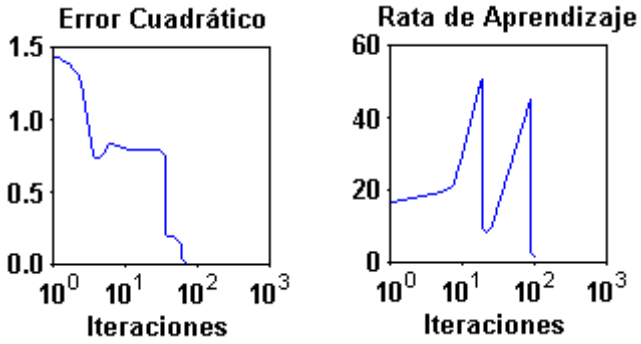

Figura 4.39:Característica de convergencia para una rata de aprendizaje variable

La figura 4.39, muestra la trayectoria de la rata de aprendizaje para este algoritmo en comparación con la característica de convergencia

Existen muchas variaciones de este algoritmo, por ejemplo Jacobs [117] propuso la regla delta-bar-delta, en la cual cada uno de los parámetros de la red, (pesos y ganancias) tenían su propia rata de aprendizaje. El algoritmo incrementa la rata de aprendizaje para un parámetro de la red si el parámetro escogido, ha estado en la misma dirección para varias iteraciones; si la dirección del parámetro escogido cambia, entonces la rata de aprendizaje es reducida.

Los algoritmos Backpropagation con momentum y con rata de aprendizaje variable son los dos métodos heurísticos más utilizados para modificar el algoritmo Backpropagation tradicional. Estas modificaciones garantizan rápida convergencia para algunos problemas, sin embargo presentan dos problemas principales: primero, requieren de un gran número de parámetros (ξ, ρ, γ), los que la mayoría de las veces se definen por un método de ensayo y error de acuerdo a la experiencia del investigador, mientras que el algoritmo tradicional, solo requiere

definir la rata de aprendizaje; segundo, estas modificaciones pueden llevar a que el algoritmo nunca converja y se torne oscilante para problemas muy complejos.
Como se menciono antes, existen también métodos de modificación basados en técnicas de optimización numérica, de esta clase de modificaciones se destacaran las más sobresalientes; es importante recalcar que estos métodos requieren una matemática más exigente, que el simple del dominio de cálculo diferencial.

4.4.3.3.2 *. Método del Gradiente Conjugado:*

Este algoritmo no involucra el cálculo de las segundas derivadas de las variables y converge al mínimo de la función cuadrática en un número finito de iteraciones. El algoritmo del gradiente conjugado, sin aplicarlo aún al algoritmo de propagación inversa consiste en:

1. Seleccionar la dirección de p_0, la condición inicial, en el sentido negativo del gradiente:

   (Ec 4-59) $$p_0 = -g_0$$

   Donde

   (Ec 4-60) $$g(k) = \nabla(ex)\big|_{x=x_k}$$

2. Seleccionar la rata de aprendizaje α_k para minimizar la función a lo largo de la dirección

   (Ec 4-61) $$x_{k+1} = x_k + \alpha_k p_k$$

3. Seleccionar la dirección siguiente de acuerdo a la ecuación

   (Ec 4-62) $$p_k = -g_k + \beta_k p_{k-1}$$

   con

   (Ec 4-63) $$\beta_k = \frac{\Delta g_k^T g_k}{\Delta g_k^T p_{k-1}} \text{ ó } \beta_k = \frac{g_k^T g_k}{g_k^T g_{k-1}}$$

4. Si el algoritmo en este punto aún no ha convergido, regresamos al numeral 2.

Este algoritmo no puede ser aplicado directamente a una red neural porque el error no es una función cuadrática; lo que afecta al algoritmo en dos formas, primero no es hábil para minimizar la función a lo largo de una línea como es requerido en el paso 2; segundo, el error mínimo no será alcanzado normalmente en un número finito de pasos y por esto el algoritmo necesitará ser inicializado después de un número determinado de iteraciones.

A pesar de estas complicaciones, esta modificación del algoritmo Backpropagation converge en muy pocas iteraciones, y es incluso uno de los algoritmos más rápidos para redes multicapa, como puede notarse en la figura 4.40

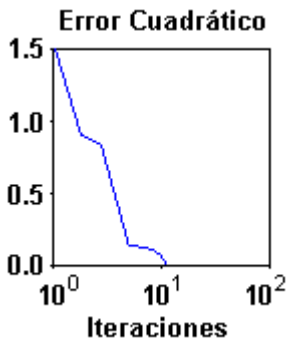

Figura 4.40:Trayectoria del Gradiente Conjugado

4.4.3.3.3 *Algoritmo de Levenberg - Marquardt:*

Este algoritmo es una modificación del método de Newton, el que fue diseñado para minimizar funciones que sean la suma de los cuadrados de otras funciones no lineales; es por ello que el algoritmo de Levenberg - Marquardt, tiene un excelente desempeño en el entrenamiento de redes neuronales donde el rendimiento de la red esté determinado por el error medio cuadrático.

El método de Newton para optimizar el rendimiento *e(x)* es:

(Ec 4-64) $$X_{k+1} = X_k - A_k^{-1} g_k$$

(Ec 4-65) $$A_k \equiv \nabla^2 (ex)\big|_{x=x_k} \qquad g_k \equiv \nabla (ex)\big|_{x=x_k}$$

Si asumimos que *e(x)* es una suma de funciones cuadráticas:

(Ec 4-66) $$e(x) = \sum_{i=1}^{n} v_i^2(x) = v^T(x)v(x)$$

El gradiente puede ser escrito entonces en forma matricial:

(Ec 4-67) $$\nabla e(x) = 2J^T(x)v(x)$$

Donde *J(x)* es la matriz Jacobiana.
Ajustando el método de Newton, obtenemos el algoritmo de Levenberg Marquardt

(Ec 4-68) $$x_{k+1} = x_k - \left[J^T(x_k)J(x_k) + \mu_k I\right]^{-1} J^T(x_k)v(x_k)$$

o

(Ec 4-69) $$\Delta x_k = -\left[J^T(x_k)J(x_k) + \mu_k I\right]^{-1} J^T(x_k)v(x_k)$$

La nueva constante μ determina la tendencia el algoritmo, cuando μ_k se incrementa, este algoritmo se aproxima al algoritmo de pasos descendientes para ratas de aprendizaje muy pequeñas; cuando μ_k se decrementa este algoritmo se convierte en el método de Gauss - Newton
El algoritmo comienza con un valor pequeño para μ_k, por lo general 0.01, si en ese paso no se alcanza el valor para *e(x)* entonces el paso es repetido con μ_k multiplicado por un factor $\nu > 1$. Si se ha escogido un valor pequeño de paso en la dirección de paso descendiente, *e(x)* debería decrecer. Si un paso produce un pequeño valor para *e(x),* entonces el algoritmo tiende al método de Gauss - Newton, el que se supone garantiza una rápida convergencia. Este algoritmo genera un compromiso entre la velocidad del método de Gauss-Newton y la garantía de convergencia del método de paso descendiente.
Los elementos de la matriz Jacobiana necesarios en el algoritmo de Levenberg-Marquardt son de este estilo:

(Ec 4-70) $$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial x_1}$$

Donde *x* es el vector de parámetros de la red, que tiene la siguiente forma:

(Ec 4-71) $$x^T = [x_1, x_2, ..., x_n] = \lfloor w^1_{1,1}, w^1_{1,2}, ... w^1_{S^1,R}, b^1_1, ..., b^1_{S^1} \rfloor$$

Para utilizar este algoritmo en las aplicaciones para redes multicapa, se redefinirá el término sensitividad de forma que sea más simple hallarlo en cada iteración.

(Ec 4-72) $$s^m_{i,h} \equiv \frac{\partial e_{k,q}}{\partial n^m_{i,q}}$$

Donde $h=(q-1)S^M + k$

Con la sensitividad definida de esta manera, los términos de la matriz Jacobiana pueden ser calculados más fácilmente:

(Ec 4-73) $$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial w^m_{i,j}} = \frac{\partial e_{k,q}}{\partial n^m_{i,q}} \times \frac{\partial n_{i,q}}{\partial w^m_{i,j}} = s^m_{i,h} \times \frac{\partial n_{i,q}}{\partial w^m_{i,j}} = s^m_{i,h} \times a^{m-1}_{j,q}$$

y para las ganancias:

(Ec 4-74) $$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial b^m_i} = \frac{\partial e_{k,q}}{\partial n^m_{i,q}} \times \frac{\partial n_{i,q}}{\partial b^m_i} = s^m_{i,h} \times \frac{\partial n_{i,q}}{\partial b^m_i} = s^m_{i,h}$$

De esta forma, cuando la entrada p_Q ha sido aplicada a la red y su correspondiente salida a^M_Q ha sido computada, el algoritmo Backpropagation de Levenberg-Marquardt es inicializado con:

(Ec 4-75) $$S^m_q = -f^m(n^m_q)$$

Cada columna de la matriz S^M_Q debe ser propagada inversamente a través de la red para producir una fila de la matriz Jacobiana. Las columnas pueden también ser propagadas conjuntamente de la siguiente manera:

(Ec 4-76) $$S^m_q = f^m(n^m_q)(W^{m+1})^T S^{m+1}_q$$

La matrices sensitividad total para cada capa en el algoritmo de Levenberg-Marquardt son formadas por la extensión de las matrices computadas para cada entrada:

(Ec 4-77) $$S^m = \left[S_1^m\right]\left[S_2^m\right]\ldots\left[S_Q^m\right]$$

Para cada nueva entrada que es presentada a la red, los vectores de sensitividad son propagados hacia atrás, esto se debe a que se ha calculado cada error en forma individual, en lugar de derivar la suma al cuadrado de los errores. Para cada entrada aplicada a la red habrá S^M errores, uno por cada elemento de salida de la red y por cada error se generara una fila de la matriz Jacobiana.

Este algoritmo puede resumirse de la siguiente manera:

1. Se presentan todas las entradas a la red, se calculan las correspondientes salidas y cada uno de los errores según

   (Ec 4-78) $$e_q = t_q - a_q^M$$

   se calcula después, la suma de los errores cuadrados para cada entrada *e(x)*
2. Se calculan las sensitividades individuales y la matriz sensitividad total y con estas, se calculan los elementos de la matriz Jacobiana.
3. Se obtiene Δx_k
4. Se recalcula la suma de los errores cuadrados usando $x_k + \Delta x_k$. Si esta nueva suma es más pequeña que el valor calculado en el paso 1 entonces se divide μ por ν, se calcula $x_{k+1} = x_k + \Delta x_{ky}$ y se regresa al paso 1. Si la suma no se reduce entonces se multiplica μ por ν

y se regresa al paso 3.

El algoritmo debe alcanzar convergencia cuando la norma del gradiente de

(Ec 4-79) $$\nabla e(x) = 2J^T(x)v(x)$$

sea menor que algún valor predeterminado, o cuando la suma de los errores cuadrados ha sido reducida a un error que se haya trazado como meta.

El comportamiento de este algoritmo se visualiza en la figura 4.41, la cual muestra la trayectoria de convergencia con $\mu = 0.01$ y $\nu = 5$

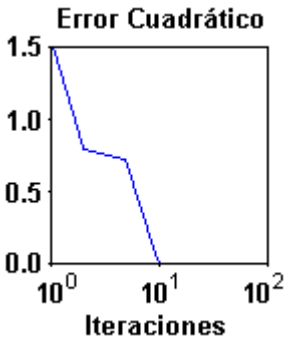

Figura 4.41:Trayectoria del algoritmo Levenberg-Marquardt

Como puede verse, este algoritmo converge en menos iteraciones que cualquier método discutido anteriormente, por supuesto requiere mucha más computación por iteración, debido a que implica el cálculo de matrices inversas. A pesar de su gran esfuerzo computacional sigue siendo el algoritmo de entrenamiento más rápido para redes neuronales cuando se trabaja con un moderado número de parámetros en la red, si el número de parámetros es muy grande utilizarlo resulta poco práctico.

CAPITULO 5

Sistemas de Inteligencia Artificial basados en probabilidad. Las Redes Bayesianas

INDICE

5 SISTEMAS DE INTELIGENCIA ARTIFICIAL BASADOS EN PROBABILIDAD. LAS REDES BAYESIANAS 133
5.1 Introducción 133
5.2 Algunos conceptos básicos de la teoría de probabilidad 133
5.2.1 Medida de Probabilidad 134
5.2.2 Distribuciones de Probabilidad 135
5.2.3 Teorema de Bayes 139
5.3 Algunos conceptos básicos sobre grafos 141
5.3.1 Introducción 141
5.3.2 Conceptos básicos y definiciones 141
5.4 Redes Bayesianas 142
5.4.1 Aprendizaje de Redes Bayesianas 143
5.4.1.1 Aprendizaje Paramétrico 144
5.4.1.2 Aprendizaje Estructural 147

5 SISTEMAS DE INTELIGENCIA ARTIFICIAL BASADOS EN PROBABILIDAD. LAS REDES BAYESIANAS

5.1 Introducción

Los sistemas de inteligencia artificial que utilizan la probabilidad como medida de incertidumbre se conocen como sistemas de inteligencia artificial probabilísticos y la estrategia de razonamiento que usan se conoce como razonamiento probabilístico o inferencia probabilística.
Las redes bayesianas modelan un fenómeno mediante un conjunto de variables y las relaciones de dependencia entre ellas. Dado este modelo, se puede hacer inferencia bayesiana; es decir, estimar la probabilidad posterior de las variables no conocidas, en base a las variables conocidas. Estos modelos pueden tener diversas aplicaciones, para clasificación, predicción, diagnóstico, etc. Además, pueden dar información interesante en cuanto a como se relacionan las variables del dominio, las cuales pueden ser interpretadas en ocasiones como relaciones de causa-efecto.
Inicialmente, estos modelos eran construidos 'a mano' basados en un conocimiento experto, pero en los últimos años se han desarrollado diversas técnicas para aprender a partir de datos, tanto la estructura como los parámetros asociados al modelo. También es posible el combinar conocimiento experto con los datos para aprender el modelo.

5.2 Algunos conceptos básicos de la teoría de probabilidad.

En este punto se describirán una serie de conceptos de la teoría de la probabilidad en los que se fundamenta los sistemas de inteligencia artificial probabilísticos:

- Medida de probabilidad.
- Distribuciones de probabilidad.
- Dependencia e Independencia.
- Teorema de Bayes.

5.2.1 Medida de Probabilidad

Para medir la incertidumbre se parte de un marco de discernimiento dado S, en el que se incluyen todos los posibles resultados de un cierto experimento como conjunto exhaustivo y mutuamente exclusivo. El conjunto S se conoce como espacio muestral. Una vez definido este conjunto, el objetivo consiste en asignar a todo subconjunto de S un número real que mida el grado de incertidumbre sobre su realización. Para obtener medidas con significado físico claro y práctico, se imponen ciertas condiciones o propiedades intuitivas adicionales que definen una clase de medidas que se conocen como medidas de probabilidad.

<u>Medida de Probabilidad</u>: Una función p que proyecta los subconjuntos $A \subseteq S$ en el intervalo [0, 1] se llama medida de probabilidad si satisface los siguientes axiomas:

- Axioma 1 (Normalización): p(S) = 1
- Axioma 2 (Aditividad): Para cualquier sucesión infinita, $A_1, A_2, \ldots$, de subconjuntos disjuntos de S, se cumple la igualdad dada por la ecuación 5-1.

(Ec 5-1) $$p\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} p(A_i)$$

El Axioma 1 establece que, independientemente de nuestro grado de certeza, ocurrirá un elemento del conjunto universal S (es decir, el conjunto S es exhaustivo). El Axioma 2 es una fórmula de agregación que se usa para calcular la probabilidad de la unión de subconjuntos disjuntos. Establece que la incertidumbre de un cierto subconjunto es la suma de las incertidumbres de sus partes (disjuntas). Nótese que esta propiedad también se cumple para sucesiones finitas.

De los axiomas anteriores pueden deducirse propiedades muy interesantes de la probabilidad. Por ejemplo:

- Propiedad 1 (Normalización): $p(\varphi) = 0$.
- Propiedad 2 (Monotonicidad): Si $A \subseteq B \subseteq S$, entonces $p(A) \leq p(B)$.
- Propiedad 3 (Continuidad Consistencia): Para toda sucesión creciente $A_1 \subseteq A_2 \subseteq \ldots$ o decreciente $A_1 \supseteq A_2 \supseteq \ldots$ de subconjuntos de S se tiene que, $\lim_{t\to\infty} p(A_i) = p(\lim_{t\to\infty} A_i)$

- Propiedad 4 (Inclusión-Exclusión): Dado cualquier par de subconjuntos A y B de S, se cumple siempre la siguiente igualdad:

(Ec 5-2) $p(A \cup B) = p(A) + p(B) - p(A \cap B)$

La Propiedad 1 establece que la evidencia asociada a una ausencia completa de información es cero. La Propiedad 2 muestra que la evidencia de la pertenencia de un elemento a un conjunto debe ser al menos la evidencia de cualquiera de sus subconjuntos. En otras palabras, la evidencia de que un elemento pertenezca a un conjunto dado A no debe decrecer con la adición de elementos al conjunto A.

La Propiedad 3 puede ser considerada como una propiedad de consistencia o continuidad. Si se eligen dos sucesiones de conjuntos que convergen al mismo subconjunto de S, se debe obtener la misma evidencia o incertidumbre. La Propiedad 4 establece que las probabilidades de los conjuntos A,B,$A \cap B$, y $A \cup B$ no son independientes, sino que están relacionadas por (Ec 5-2).

Un ejemplo clásico que ilustra estos axiomas es el del lanzamiento de un dado no trucado. Aquí el espacio muestral es S = {1, 2, 3, 4, 5, 6}, es decir, el conjunto de los posibles resultados del lanzamiento. Sea p(A) la probabilidad de que ocurra el suceso A. Entonces, por ejemplo, se tiene p(S) = 1, p({1}) = 1/6, p({3}) = 1/6, y p({1, 3}) = p({1})+p({3}) = 1/3.

5.2.2 Distribuciones de Probabilidad

Sea $\{X_1,\ldots, X_n\}$ un conjunto de variables aleatorias discretas y $\{x_1,\ldots, x_n\}$ el conjunto de sus posibles realizaciones. Nótese que las variables aleatorias se denotan con mayúsculas y que sus realizaciones se denotan con minúsculas. Por ejemplo, si X_i es una variable binaria, entonces x_i puede ser 1 ó 0. Los resultados que siguen son también válidos si las variables son continuas, pero en este caso los símbolos de suma deben sustituirse por integrales.

Sea $p(x_1,\ldots,x_n)$ la función de probabilidad conjunta[1] de las variables de X, es decir,

(Ec 5-3) $p(x_1, \ldots, x_n) = p(X_1 = x_1, \ldots, X_n = x_n)$.

[1] Cuando las variables son discretas, $p(x_1,\ldots, x_n)$ se llama función de probabilidad, y cuando las variables son continuas, se llama función de densidad. Por simplicidad, nos referiremos a ambas como función de probabilidad conjunta de las variables.

Entonces, la función de probabilidad marginal de la i-ésima variable se obtiene mediante la fórmula

$$\text{(Ec 5-4)} \quad p(x_i) = p(X_i = x_i) = \sum_{x_i,\ldots x_{i-1}, x_{i+1},\ldots,x_n} p(x_1, \ldots, x_n).$$

El conocimiento de la ocurrencia de un suceso puede modificar las probabilidades de otros sucesos. Por ejemplo, la probabilidad de que un paciente tenga una enfermedad dada puede cambiar tras el conocimiento de los resultados de un análisis de sangre. Por ello, cada vez que se dispone de nueva información, las probabilidades de los sucesos pueden, y suelen, cambiar. Esto conduce al concepto de probabilidad condicional: Sean X e Y dos conjuntos disjuntos de variables tales que p(y) > 0. Entonces, la probabilidad condicional (función de probabilidad condicionada) de X dado Y = y viene dada por

$$\text{(Ec 5-5)} \quad p(X = x \mid Y = y) = p(x \mid y) = \frac{p(x, y)}{p(y)}$$

La ecuación 5-5 implica que la función de probabilidad conjunta de X e Y puede escribirse como

$$\text{(Ec 5-6)} \quad p(x, y) = p(y)p(x|y)$$

Se obtiene un caso particular de (Ec 5-5) cuando X es una única variable e Y es un subconjunto de variables. En este caso, (Ec 5-5) se convierte en (Ec 5-7).

$$\text{(Ec 5-7)} \quad p(x_i \mid x_1, \ldots, x_k) = \frac{p(x_i, x_1, \ldots, x_k)}{p(x_1, \ldots, x_k)} = \frac{p(x_i, x_1, \ldots, x_k)}{\sum_{x_i} p(x_i, x_1, \ldots, x_k)}$$

La ecuación 5-7 es la función de probabilidad de la i-ésima variable, X_i, dado el subconjunto de variables $\{X_1,\ldots, X_k\}$. La suma del denominador de (Ec 5-7) se extiende a todos los valores posibles de X_i. Nótese que ambas, las fórmulas de la probabilidad marginal en (Ec 5-4) y de la probabilidad condicional en (Ec 5-5) siguen siendo válidas si la variable X_i se reemplaza por un subconjunto de variables siempre que los conjuntos de variables sean disjuntos. Nótese también que si el conjunto $\{X_1,\ldots, X_k\}$ en (Ec 5-5) se sustituye por el conjunto vacío φ, entonces (Ec 5-5) se convierte en $p(x_i)$. Por ello, puede pensarse de la probabilidad marginal como un caso particular de probabilidad condicional.

3.2.3 Dependencia e Independencia

Sean X e Y dos subconjuntos disjuntos del conjunto de variables aleatorias $\{X_1, \ldots, X_n\}$. Entonces se dice que X es independiente de Y si y solamente si se cumple (Ec 5-8) para todos los valores posibles x e y de X e Y ; en otro caso, X se dice dependiente de Y.

(Ec 5-8) $p(x|y) = p(x)$

Nótese que si x e y son valores posibles de X e Y , entonces $p(x) > 0$ y $p(y) > 0$. Por ello, la condición $p(y) > 0$ es natural en el sentido de que no puede observarse Y = y si no se satisface la condición.

La ecuación (Ec 5-8) significa que si X es independiente de Y , entonces nuestro conocimiento de Y no afecta nuestro conocimiento sobre X, es decir, Y no tiene información sobre X. También, si X es independiente de Y, pueden combinarse (Ec 5-6) y (Ec 5-8) para obtener $p(x, y)/p(y) = p(x)$, que implica

(Ec 5-9) $p(x, y) = p(x)p(y)$

La ecuación (Ec 5-9) indica que si X es independiente de Y, entonces la función de probabilidad conjunta de X e Y es igual al producto de sus marginales.

En realidad (Ec 5-9) es una definición de independencia equivalente a la (Ec 5-8).

Una propiedad importante de la relación de independencia es su simetría, es decir, si X es independiente de Y, entonces Y es independiente de X. Esto ocurre porque

(Ec 5-10) $$p(y \mid x) = \frac{p(x, y)}{p(x)} = \frac{p(x)p(y)}{p(x)} = p(y).$$

Por la propiedad de simetría se dice que X e Y son independientes o mutuamente independientes. La implicación práctica de la simetría es que si el conocimiento de Y es relevante (irrelevante) para X, entonces el conocimiento de X es relevante (irrelevante) para Y . Los conceptos de dependencia e independencia de dos variables aleatorias pueden ser extendidos al caso de más de dos variables aleatorias como sigue:

Independencia de un conjunto de variables. Las variables aleatorias $\{X_1, \ldots, X_m\}$ se dice que son independientes si y sólo si se cumple (Ec 5-11) para todos los valores posibles $x_1, \ldots, x_m$ de $X_1, \ldots, X_m$. En otro caso, se dice que son dependientes.

$$\text{(Ec 5-11)} \quad p(x_1, \ldots, x_m) = \prod_{i=1}^{m} p(x_i)$$

En otras palabras, $\{X_1,\ldots, X_m\}$ se dicen independientes si y sólo si su función de probabilidad conjunta es igual al producto de sus funciones de probabilidad marginal. Nótese que (Ec 5-11) es una generalización de (Ec 5-9).

Nótese también que si $X_1,\ldots, X_m$ son condicionalmente independientes dado otro subconjunto $Y_1,\ldots, Y_n$, entonces

$$\text{(Ec 5-12)} \quad p(x_1, \ldots, x_m \mid y_1, \ldots, y_n) = \prod_{i=1}^{m} p(x_i \mid y_1, \ldots, y_n).$$

Una implicación importante de la independencia es que no es rentable obtener información sobre variables independientes, pues es irrelevante. Es decir, independencia significa irrelevancia.

Dependencia e independencia condicional. Sean X, Y y Z tres conjuntos disjuntos de variables, entonces X se dice condicionalmente independiente de Y dado Z, si y sólo si se cumple (Ec 5-13) para todos los valores posibles de x, y, z de X, Y y Z. En otro caso X e Y se dicen condicionalmente dependientes dado Z.

$$\text{(Ec 5-13)} \quad p(x|z, y) = p(x|z)$$

Cuando X e Y son condicionalmente independientes dado Z, se escribe $I(X, Y|Z)$. La relación $I(X, Y|Z)$ se denomina relación de independencia condicional. Similarmente, cuando X e Y son condicionalmente dependientes dado Z, se escribe $D(X, Y|Z)$, que se conoce como una relación de dependencia condicional. A veces escribimos $I(X, Y|Z)_p$ o $D(X, Y|Z)_p$ para indicar que la relación se deriva, o es implicada, por el modelo probabilístico asociado a la probabilidad p (la función de probabilidad conjunta).

La definición de independencia condicional lleva en sí la idea de que una vez que es conocida Z, el conocimiento de Y no altera la probabilidad de X. En otras palabras, si Z ya es conocida, el conocimiento de Y no añade información alguna sobre X.
Una definición alternativa, pero equivalente, de independencia condicional es la expresada en (Ec 5-14).

(Ec 5-14) $p(x, y|z) = p(x|z)p(y|z)$.

La equivalencia de (Ec 5-13) y (Ec 5-14) puede demostrarse de forma similar a la de (Ec 5-8) y (Ec 5-9).
La independencia (incondicional) puede ser tratada como un caso particular de la independencia condicional. Por ejemplo, se puede escribir $I(X, Y|\varphi)$, para indicar que X e Y son incondicionalmente independientes, donde φ es el conjunto vacío. Nótese, sin embargo, que X e Y pueden ser independientes incondicionalmente pero condicionalmente dependientes dado Z, es decir, la relación de independencia condicional $I(X, Y|\varphi)$ y la de dependencia condicional $D(X, Y|Z)$ pueden satisfacerse simultáneamente.

5.2.3 Teorema de Bayes

En teoría de la probabilidad, el teorema de Bayes es la regla básica para realizar inferencias. Así, el teorema de Bayes nos permite actualizar la creencia que tenemos en un suceso o conjunto de sucesos a la luz de nuevos datos u observaciones. Es decir, nos permite pasar de la probabilidad a priori P(suceso) a la probabilidad a posteriori P(suceso/observaciones). La probabilidad a priori puede verse como la probabilidad inicial, la que fijamos sin saber nada más. Por ejemplo, si estamos en invierno, la probabilidad de que una persona padezca gripe en un momento determinado podría ser del 0,05 (P(Gripe=sí) = 0,05). La probabilidad a posteriori es la que obtendríamos tras conocer cierta información. Puede verse como un refinamiento de nuestro conocimiento. Por ejemplo, si sabemos que la persona en cuestión se ha vacunado contra la gripe, entonces la probabilidad a posteriori sería prácticamente cero (P(Gripe=sí / Vacuna=sí) $\approx$ 0). Teniendo en cuenta estos conceptos, el teorema de Bayes viene representado por la siguiente expresión:

(Ec 5-15) $$P(h/O) = \frac{P(O/h).P(h)}{P(O)}$$

Donde, como podemos ver, lo que aparecen son la probabilidad a priori de la hipótesis (h) y de las observaciones (O) y las probabilidades condicionadas P(h/O) y P(O/h). A esta última se le conoce como la verosimilitud de que la hipótesis h haya producido el conjunto de observaciones O.

Centrándonos en el problema de la clasificación, con una variable clase (C) y un conjunto de variables predictoras o atributos $\{A_i, \ldots, A_n\}$, el teorema de Bayes tendría la forma de la ecuación 5-16.

(Ec 5-16) $$P(C / A_1 \ldots A_n) = \frac{P(A_1 \ldots A_n / C) \cdot P(C)}{P(A_1 \ldots A_n)}$$

Evidentemente, si C tiene k posibles valores $\{c_1, \ldots, c_k\}$, lo que nos interesa es identificar el más plausible y devolverlo como resultado de la clasificación. En el marco bayesiano, la hipótesis más plausible no es otra que aquella que tiene máxima probabilidad a posteriori dados los atributos, y es conocida como la hipótesis máxima a posteriori o hipótesis MAP (del inglés, maximum a posteriori). Así, la calse o valor a devolver es según se indica en Ec 5-17.

(Ec 5-17) $$c_{MAP} = \underset{c \in \Omega_c}{\operatorname{argmax}}\, p(c \mid A_1 \ldots A_n) = \underset{c \in \Omega_c}{\operatorname{argmax}} \frac{P(A_1 \ldots A_n \mid C).P(C)}{P(A_1 \ldots A_n)} = \underset{c \in \Omega_c}{\operatorname{argmax}}\, p(A_1 \ldots A_n \mid c).p(c)$$

Donde Ω_c representa el conjunto de valores que puede tomar la variable C. Nótese que en el último paso se ha eliminado la división debido a que el divisor sería el mismo para todas las categorías. Por tanto el teorema de Bayes nos facilita un método sencillo y con una semántica clara para resolver esta tarea. Sin embargo, este método tiene un problema, y es su altísima complejidad computacional debido a que necesitamos trabajar con distribuciones de probabilidad que involucran muchas variables, haciéndolas en la mayoría de los casos inmanejables. Este problema es paliado haciendo uso de las (a veces supuestas) independencias entre las variables.

5.3 Algunos conceptos básicos sobre grafos

5.3.1 Introducción

En este apartado se presentan algunos conceptos sobre la teoría de grafos que son muy útiles para definir sistemas expertos y otros modelos utilizados en el área de la inteligencia artificial. Muchos de los resultados teóricos de la teoría de grafos pueden ser utilizados para analizar diversos aspectos de estos campos. [124-130]

5.3.2 Conceptos básicos y definiciones

Supóngase un conjunto de objetos $X = \{X_1, X_2, \ldots, X_n\}$ que pueden relacionarse entre sí. El conjunto X puede ser representado gráficamente por una colección de nodos o vértices, asociando un nodo a cada elemento de X. Estos nodos pueden conectarse por aristas, indicando las relaciones existentes entre los mismos. Una arista entre los nodos X_i y X_j se denotará mediante L_{ij} . Así mismo, el conjunto de todas las aristas se denotará por $L = \{L_{ij} \mid X_i$ y X_j están conectados$\}$. Por tanto, un grafo puede definirse de forma intuitiva mediante el conjunto de nodos, X, y las relaciones entre los mismos, L.
Un grafo es un par de conjuntos G =(X,L), donde $X = \{X_1, X_2, \ldots, X_n\}$ es un conjunto finito de elementos (nodos), y L es un conjunto de aristas, es decir, un subconjunto de pares ordenados de elementos distintos de X. Los términos grafo y red se emplearán como sinónimos en este trabajo.
El concepto de grafo puede definirse de forma más general. Por ejemplo, puede permitirse que dos nodos estén conectados por más de una arista, o incluso que un nodo está conectado consigo mismo. Sin embargo, en el campo de los sistemas expertos, los grafos se utilizan para representar un conjunto de variables proposicionales (nodos), y unas relaciones de dependencia entre ellas (aristas). Por tanto, no es necesario que dos nodos estén unidos por más de una arista, o que una arista una un nodo consigo mismo. Las aristas de un grafo pueden ser dirigidas o no dirigidas, dependiendo de si se considera o no, el orden de los nodos.

<u>Arista dirigida</u>**:** Dado un grafo G = (X,L), si $L_{ij} \in L$ y $L_{ji} \notin L$, la arista L_{ij} entre los nodos X_i y X_j se denomina dirigida y se denota mediante $X_i \rightarrow X_j$.

Arista no dirigida**:** Dado un grafo G = (X,L), si $L_{ij} \in L$ y $L_{ji} \in L$, la arista L_{ij} se denomina no dirigida y se denota mediante $X_i - X_j$ o $X_j - X_i$.

Grafo dirigido y no dirigido**:** Un grafo en el cual todas las aristas son dirigidas se denomina grafo dirigido, y un grafo en el que todas sus aristas son no dirigidas se denomina no dirigido.

Por tanto, en un grafo dirigido es importante el orden del par de nodos que definen cada arista, mientras que en un grafo no dirigido, el orden carece de importancia.

5.4 Redes Bayesianas

Las Redes Bayesianas (RBs) son un formalismo que en los últimos años ha demostrado su potencialidad como modelo de representación del conocimiento con incertidumbre [133]. Este formalismo nació como una aportación de diferentes campos de investigación: teoría de toma de decisiones, estadística e inteligencia artificial. El éxito de numerosas aplicaciones en campos variados como la medicina, la recuperación de información, la meteorología, la visión artificial, la fusión de información, la agricultura, etc., avalan este formalismo.

Las RBs representan el conocimiento cualitativo del modelo mediante un grafo dirigido acíclico. Este conocimiento se articula en la definición de relaciones de independencia/ dependencia entre las variables que componen el modelo. Estas relaciones abarcan desde una independencia completa hasta una dependencia funcional entre variables del modelo. El hecho de utilizar una representación gráfica para la especificación del modelo hace de las RBs una herramienta realmente muy atractiva en su uso como representación del conocimiento.

Las RBs no sólo modelan de forma cualitativa el conocimiento sino que además expresan de forma numérica la "fuerza" de las relaciones entre las variables. Esta parte cuantitativa del modelo suele especificarse mediante distribuciones de probabilidad como una medida de la creencia que tenemos sobre las relaciones entre variables de modelo.

Formalmente, una red bayesiana es una tupla $B=(G,\Theta)$, donde G es el grafo y Θ es el conjunto de distribuciones de probabilidad $P(X_i \mid P_a(X_i))$ para cada variable desde i=1 hasta n y $P_a(X_i)$ representa los padres de la variable X_i en el grafo G [131].

El formalismo que vamos a utilizar para representar la parte cuantitativa del modelo de red es la teoría de la probabilidad. En entornos probabilísticos, una distribución de probabilidad P puede ser considerada un modelo de dependencias (Ec 5-18) donde X, Y, Z son subconjuntos de variables del modelo y la sentencia I(.,.|.) se interpreta como una relación de independencia condicional.

(Ec 5-18) $I(X,Y \mid Z) \Leftrightarrow P(X \mid YZ) = P(X \mid Z)$

La ecuación 5-18 se leería como "X es condicionalmente independiente de Y conocido Z". En un entorno probabilístico el conocimiento cuantitativo viene expresado por una distribución de probabilidad conjunta definida sobre las variables del modelo. La codificación de las relaciones de independencia condicional expresadas en una RB hace que la distribución de probabilidad conjunta se pueda almacenar de una manera mucho más eficiente y local a cada una de las variables del modelo (Ec 5-19).

(Ec 5-19) $P(X_1 \ldots, X_n) = \prod_{i=1}^{n} P(X_i \mid P_a(X_i))$

Por ejemplo, si se tuviera n variables aleatorias binarias (discretas con dos valores), necesitaríamos almacenar O(2") parámetros para especificar la distribución de probabilidad conjunta $P(X_1, X_2, \ldots, X_n)$. Sin embargo, una red bayesiana puede necesitar un número exponencialmente menor de parámetros, dado que para cada variable tan sólo hay que almacenar una distribución de probabilidad condicionada a su conjunto de padres en el grafo previamente especificado.

Una vez que hemos definido las RBs, se pueden destacar dos problemas fundamentales para trabajar con este formalismo. Por un lado, se trata de utilizar éstas para realizar procesos eficientes de razonamiento una vez que tengamos especificado el modelo completo tanto cualitativa como cuantitativamente. Para este tipo de tareas han sido muchos los trabajos realizados [132]. La existencia de estos algoritmos cada vez más eficientes hace que aparezcan cada vez más aplicaciones prácticas muy interesantes que utilizan las redes bayesianas como motor de inferencia en sus sistemas. Por otro lado, el segundo problema es la tarea de su construcción.

5.4.1 Aprendizaje de Redes Bayesianas

El aprendizaje de redes bayesianas consiste en inducir un modelo, estructura y parámetros asociados, a partir de datos. Este puede dividirse naturalmente en dos partes:

1. Aprendizaje estructural. Obtener la estructura o topología de la red.
2. Aprendizaje paramétrico. Dada la estructura, obtener las probabilidades asociadas.

5.4.1.1 Aprendizaje Paramétrico

Cuando se tienen datos completos y suficientes para todas las variables en el modelo, es relativamente fácil obtener los parámetros, asumiendo que la estructura está dada. El método más común es el llamado estimador de máxima verosimilitud, bajo el cual se estiman las probabilidades en base a las frecuencias de los datos. Para una red bayesiana se tienen dos casos:

- Nodos raíz. Se estima la probabilidad marginal. Por ejemplo: $P(A_i) \sim NA_i/N$, donde NA_i es el número de ocurrencias del valor i de la variable A,y N es el número total de casos o registros.
- Nodos hoja. Se estima la probabilidad condicional de la variable dados sus padres. Por ejemplo: $P(B_i \mid A_j, C_k) \sim NB_iA_jC_k / NA_jC_k$, donde $NB_iA_jC_k$ es el número de casos en que $B = B_i$, $A = A_j$ y $C = C_k$ y NA_jC_k es el número de casos en que $A = A_j$ y $C = C_k$.

Dado que normalmente no se tienen suficientes datos, se tiene incertidumbre en las probabilidades estimadas. Esta incertidumbre se puede representar mediante una distribución de probabilidad, de forma que se considere en forma explícita la incertidumbre sobre las probabilidades. Para el caso de variables binarias se modela con una distribución Beta y para variables multivaluadas mediante su extensión, que es la distribución Dirichlet. Para el caso binario, con una distribución Beta, el valor esperado (promedio) estado por: $P(b_i)= a +1/a + b + 2$, donde a y b son los parámetros de la distribución. Esta representación puede utilizarse para modelar la incertidumbre cuando se tienen estimaciones de expertos, cambiando los valores de a + b, con el mismo valor estimado.

<u>Datos incompletos:</u>

En la práctica, en muchas ocasiones los datos no están completos. Hay dos tipos básicos de información incompleta:

- Valores faltantes: Faltan algunos valores de una de las variables en algunos casos.
- Nodos ocultos: Faltan todos los valores de una variable.

Cuando existen valores faltantes, que es el caso más sencillo, existen varias alternativas, entre ellas:

⇒ Eliminar los casos (registros) donde aparecen valores faltantes.

⇒ Considerar un nuevo valor adicional para la variable, como 'desconocido'.

⇒ Tomar el valor más probable (promedio) de la variable.

⇒ Considerar el valor más probable en base a las otras variables

⇒ Considerar la probabilidad de los diferentes valores en base a las otras variables.

Las primeras dos alternativas pueden ser adecuadas cuando se tienen muchos datos, pero si no, se está de alguna manera desaprovechando información. La tercera alternativa no considera las demás variables del modelo, por lo que normalmente no da los mejores resultados. La cuarta y quinta alternativa son las más interesantes y en general las mejores.
Para el caso del valor más probable se parte de una red bayesiana inicial construida en base a los datos completos. Posteriormente se complementa el modelo usando los registros con datos incompletos, en base al siguiente algoritmo:

1. Asignar todas las variables observadas en el registro.
2. Propagar su efecto y obtener las probabilidades posteriores de las no observables.
3. Para las variables no observables, asumir el valor con probabilidad mayor como observado.
4. Actualizar las probabilidades previas y condicionales en el modelo.
5. Repetir 1 a 4 para cada observación.

Esto se puede mejorar si en vez de tomar el valor más probable, se considera cada caso como varios casos parciales, en base a la probabilidad posterior de cada valor de la variable faltante.
Cuando existen nodos ocultos, se pueden también estimar las tablas de probabilidad condicional faltantes. El método más comúnmente utilizado es el de la 'maximización de la expectación' (EM, por sus siglas en inglés, expectation maximization).
El algoritmo EM es un método estadístico muy utilizado para estimar probabilidades cuando hay variables no observables. Consiste básicamente de dos pasos que se repiten en forma iterativa:

Paso 1: se estiman los datos faltantes en base a los parámetros actuales.
Paso 2: se estiman las probabilidades (parámetros) considerando los datos estimados.

Para el caso de nodos ocultos en redes bayesianas, el algoritmo EM es el siguiente:

1 Iniciar los parámetros desconocidos (probabilidades condicionales) con valores aleatorios (o estimaciones de expertos).

2 Utilizar los datos conocidos con los parámetros actuales para estimar los valores de la variable(s) oculta(s).
3 Utilizar los valores estimados para completar la tabla de datos.
4 Re-estimar los parámetros con los nuevos datos.
5 Repetir 2–4 hasta que no haya cambios significativos en las probabilidades.

La principal limitación de EM es que puede caer en óptimos locales, por lo que los valores finales obtenidos pueden depender de la inicialización.

Discretización de variables continuas:

Normalmente las redes bayesianas consideran variables discretas o nominales, por lo que si no lo son, hay que discretizarlas antes de construir el modelo. Aunque existen modelos de redes bayesianas con variables continuas, estos están limitados a variables Gaussianas y relaciones lineales.
Los métodos de discretización se dividen en dos tipos principales: (i) no supervisados y (ii) supervisados.
Los métodos de no supervisados no consideran la variable clase, así que los atributos continuos son discretizados independientemente. El método más simple es dividir el rango de valores cada atributo, [Xmin; Xmax], en k intervalos, donde k es dado por el usuario u obtenido usando una cierta medida de información sobre los valores de los atributos.
Los métodos supervisados consideran la variable clase, es decir los puntos de división para formar rangos en cada atributo son seleccionados en función del valor de la clase. El problema de encontrar el número óptimo de intervalos y de los límites correspondientes se puede considerar como un problema de búsqueda. Es decir, podemos generar todos los puntos posibles de división para formar intervalos sobre la gama de valores de cada atributo (donde hay un cambio en la clase), y estimamos el error de clasificación para cada partición posible (usando por ejemplo, validación cruzada). Desafortunadamente, la generación y la prueba de todas las posibles particiones es impráctica, por lo que normalmente se realiza una búsqueda heurística.
El enfoque supervisado se aplica directamente al caso de los clasificadores bayesianos. Por ejemplo, para un atributo continuo, A, se comienza con un número inicial de particiones. Entonces hace una búsqueda iterativa para encontrar una mejor partición, uniendo o particionando intervalos, y probando la exactitud del clasificador después de cada operación. Esta es básicamente una búsqueda 'glotona' (hill-climbing), que se detiene cuando la exactitud

ya no puede ser mejorada.

Para el caso general de una red bayesiana, existe un método para la discretización de atributos continuos, mientras se aprende la estructura de la red bayesiana. La discretización esta basada en el principio de MDL, considerando el número de intervalos de una variable con respecto a sus vecinos en la red. Para una estructura dada, un procedimiento de búsqueda local encuentra la discretización de una variable que reduce al mínimo la longitud de la descripción referente a los nodos adyacentes en la red, y éste se repite en forma iterativa para cada una de las variables continuas.

5.4.1.2 Aprendizaje Estructural

El aprendizaje estructural consiste en encontrar las relaciones de dependencia entre las variables, de forma que se pueda determinar la topología o estructura de la Red Bayesiana. De acuerdo al tipo de estructura, podemos dividir los métodos de aprendizaje estructural en:

- Aprendizaje de árboles.
- Aprendizaje de poliárboles.
- Aprendizaje de redes multiconectadas.

Para el caso más general, que es el de redes multiconectadas, existen dos clases de métodos:

1. Métodos basados en medidas y búsqueda.
2. Métodos basados en relaciones de dependencia.

<u>Aprendizaje de árboles</u>

El aprendizaje de árboles se basa en el algoritmo desarrollado por Chow y Liu para aproximar una distribución de probabilidad por un producto de probabilidades de segundo orden (árbol). La probabilidad conjunta de n-variables se puede representar según Ec 5-20.

$$\text{(Ec 5-20)} \quad P(X_1, X_2, ..., X_n) = \prod_{i=1}^{n} P(X_i \mid X_{j(i)})$$

donde $X_{j(i)}$ es el padre de X_i.

Para obtener el árbol se plantea el problema como uno de optimización: obtener la estructura

de árbol que más se aproxime a la distribución 'real'. Esto se basa en una medida de la diferencia de información entre la distribución real (P) y la aproximada (P *):

$$\text{(Ec 5-21)}\quad DI(P, P^*) = \sum_x P(X)\log(P(X)/P^*(X))$$

El objetivo es minimizar DI. Se puede definir dicha diferencia en función de la información mutua entre pares de variables, que se define como Ec 5-22:

$$\text{(Ec 5-22)}\quad I(X_i, X_j) = \sum_{X_i, X_j} P(X_i, X_j)\log(P(X_i, X_j)/P(X_i)P(X_j))$$

Se puede demostrar que la diferencia de información es una función del negativo de la suma de las informaciones mutuas (pesos) de todos los pares de variables que constituyen el árbol. Entonces, encontrar el árbol más próximo equivale a encontrar el árbol con mayor peso.
Podemos entonces encontrar el árbol óptimo mediante el siguiente algoritmo, que es equivalente al conocido problema del maximum weight spanning tree:

1. Calcular la información mutua entre todos los pares de variables (que para n variables, son n(n −1)/2).
2. Ordenar las informaciones mutuas de mayor a menor.
3. Seleccionar la rama de mayor valor como árbol inicial.
4. Agregar la siguiente rama mientras no forme un ciclo, si es así, desechar.
5. Repetir 4 hasta que se cubran todas las variables (n-1 ramas).

Aprendizaje de poliárboles

Una forma de darle direcciones al 'esqueleto' aprendido con el algoritmo de Chow y Liu, es mediante pruebas de independencias no sólo entre dos variables, sino entre grupos de tres variables o tripletas. Mediante este esquema se genera un algoritmo que aprende poliárboles, ya que al signar las direcciones puede ser que la estructura generada sea un árbol o un poliárbol (en realidad, un árbol es un caso especial de poliárbol).
El algoritmo parte del esqueleto (estructura sin direcciones) obtenido con el algoritmo de Chow y Liu. Después se determinan las direcciones de los arcos utilizando pruebas de dependencia entre tripletas de variables. Dadas tres variables, existen tres casos posibles:

1. Arcos secuenciales: $X \rightarrow Y \rightarrow Z$.
2. Arcos divergentes: $X \leftarrow Y \rightarrow Z$.
3. Arcos convergentes: $X \leftarrow Y \leftarrow Z$.

Los primeros dos casos son indistinguibles en base a pruebas de independencias; es decir, son equivalentes. En ambos, X y Z son independientes dado Y. Pero el tercero es diferente, ya que las variables X y Z son marginalmente independientes. Este tercer caso lo podemos usar para determinar entonces las direcciones de los dos arcos que unen estas tres variables, y a partir de éstos, es posible encontrar las direcciones de otros arcos utilizando pruebas de independencia. De acuerdo a lo anterior, se establece el siguiente algoritmo para aprendizaje de poliárboles:

1. Obtener el esqueleto utilizando el algoritmo de Chow y Liu.
2. Recorrer la red hasta encontrar una tripleta de nodos que sean convergentes, donde la variable a la que apuntan los arcos la llamaremos nodo multipadre.
3. A partir de un nodo multipadre, determinar las direcciones de otros arcos utilizando la prueba de dependencia de tripletas, hasta donde sea posible (base causal).
4. Repetir 2-3 hasta que ya no se puedan descubrir más direcciones.
5. Si quedan arcos sin direccionar, utilizar semántica externa para obtener su dirección.

<u>Aprendizaje de redes</u>

Existen dos clases de métodos para el aprendizaje genérico de redes bayesianas, que incluyen redes multiconectadas. Estos son:

1. Métodos basados en medidas de ajuste y búsqueda.
2. Métodos basados en pruebas de independencia.

a) Aprendizaje basado en medidas globales

En esta clase de métodos se tiene una evaluación global de la estructura respecto a los datos. Es decir, se generan diferentes estructuras y se evalúan respecto a los datos utilizando alguna medida de ajuste. Existen diferentes variantes de estos métodos que dependen básicamente de dos aspectos principales: (i) medida de ajuste de la estructura a los datos, y (ii) método de búsqueda de la mejor estructura.

Hay varias posibles medidas de ajuste, las dos más comunes son la medida bayesiana y la

medida basada en el principio de longitud de descripción mínima (MDL). La medida bayesiana busca maximizar la probabilidad de la estructura dados los datos: P (Bs | D); donde Bs es la estructura y D son los datos. La cual podemos escribir en términos relativos al comparar dos estructuras, i y j, según Ec 5-23.

(Ec 5-23) $P(Bsi \mid D)/P(Bsj \mid D) = P(Bsi, D)/P(Bsj, D)$

Considerando variables discretas y que los datos son independientes, las estructuras se pueden comparar en función del número de ocurrencias (frecuencia) de los datos predichos por cada estructura.

La medida MDL hace un compromiso entre la exactitud y la complejidad del modelo. La exactitud se estima midiendo la información mutua entre los atributos y la clase; y la complejidad contando el número de parámetros. Una constante, α, en [0, 1], se utiliza para balancear el peso de cada aspecto, exactitud contra complejidad. Así, la medida de calidad está dada por Ec 5-24.

(Ec 5-24) $MC = \alpha(W/Wmax) + (1-\alpha)(1-L/Lmax)$

donde W representa la exactitud del modelo y L la complejidad, mientras que Wmax y Lmax representan la máxima exactitud y complejidad, respectivamente. Para determinar estos máximos normalmente se considera una limitación en cuanto al número de padres máximo permitido por nodo. Un valor α =0.5 da la misma importancia a complejidad y exactitud, mientras que un valor cercano a 0 considera darle mayor importancia a la complejidad y cercano a uno mayor importancia a exactitud.

La complejidad está dada por el número de parámetros requeridos para representar el modelo, la cual se puede calcular según Ec 5-25.

(Ec 5-25) $L = S_i[k_i \log_2 n + d(S_i - 1)F_i]$

Donde, n es el número de nodos, k es el número de padres por nodo, S_i es el número de valores promedio por variable, F_i el número de valores promedio de los padres, y d el número de bits por parámetro.

La exactitud se puede estimar en base al 'peso' de cada nodo, en forma análoga a los pesos en el método de aprendizaje de árboles. En este caso el peso de cada nodo, x_i, se estima en base a la información mutua con sus padres, Fx_i (Ec 5-26).

(Ec 5-26) $$w(x_i, Fx_i) = \sum_{x_i} P(x_i, Fx_i)\log[P(x_i, Fx_i)/P(x_i)P(Fx_i)]$$

y el peso (exactitud) total está dado por la suma de los pesos de cada nodo (Ec 5-27)

(Ec 5-27) $$W = \sum_i w(x_i, Fx_i)$$

Una vez establecida una forma de medir la calidad de una estructura, se establece un método para hacer una búsqueda de la 'mejor' estructura entre todas las estructuras posibles. Dado que el número de posibles estructuras es exponencial en el número de variables, es imposible evaluar todas las estructuras, por lo que se hace una búsqueda heurística. Se pueden aplicar diferentes métodos de búsqueda. Una estrategia común es utilizar búsqueda de ascenso de colinas (hill climbing), en la cual se inicia con una estructura simple (árbol) que se va mejorando hasta llegar a la 'mejor' estructura. El algoritmo de búsqueda de la mejor estructura es el siguiente:

a) Generar una estructura inicial (árbol). ´
b) Calcular la medida de calidad de la estructura inicial.
c) Agregar / invertir un arco en la estructura actual.
d) Calcular la medida de calidad de la nueva estructura.
e) Si se mejora la calidad, conservar el cambio; si no, dejar la estructura anterior.
f) Repetir 3 a 5 hasta que ya no haya mejoras.

El algoritmo anterior no garantiza encontrar la estructura óptima, ya que puede llegar a un máximo local. Se pueden utilizar otros métodos de búsqueda como algoritmos genéticos, recocido simulado, búsquedas bidireccionales, etc.

b) Aprendizaje basado en pruebas de independencia

A diferencia del enfoque basado en una medida global, este enfoque se basa en medidas de dependencia local entre subconjuntos de variables. El caso más sencillo es el del algoritmo de Chow y Liu, en el cual se mide la información mutua entre pares de variables. A partir de estas medidas se genera una red bayesiana en forma de árbol. Analizando dependencias entre tripletas de variables, el método se extiende a poliárboles.
Este enfoque se puede generalizar para el aprendizaje de redes multiconectadas, haciendo pruebas de dependencia entre subconjuntos de variables, normalmente dos o tres variables.

Por ejemplo, se puede continuar el método de Chow y Liu agregando más arcos aunque se formen ciclos, hasta un cierto umbral mínimo de información mutua. La desventaja es que pueden generarse muchos arcos 'innecesarios', por lo que se incorporan formas de luego eliminar arcos.

Hay diferentes variantes de este enfoque que consideran diferentes medidas de dependencia y diferentes estrategias para eliminar arcos innecesarios.

CAPITULO 6

Métodos Measure-Correlate-Predict (MCP) para la estimación de datos eólicos

.

INDICE

6. METODOS MEASURE-CORRELATE-PREDICT (MCP) PARA LA ESTIMACION DE DATOS EOLICOS. 153
6.1. Introducción. 153
6.2. Método de Derrick 154
6.3. Método de Niesel et al 155
6.4. Método de García Rojo 156
6.5. Método de Rogers et al (Variance Ratio Method) [9] 157
6.6. El Método Weibull Scale (WSM) 158
6.7. Nuevo Método MCP propuesto en la presente tesis 159

6. METODOS MEASURE-CORRELATE-PREDICT (MCP) PARA LA ESTIMACION DE DATOS EOLICOS.

6.1. Introducción.

Este tipo de método de Measure-Correlate-Predict (MCP) se viene utilizando desde hace décadas en la estimación de datos eólicos a largo plazo. Existen diversas variantes pero, en general, todos se basan en la existencia de correlaciones estadísticas entre dos series temporales que abarca un periodo corto de tiempo, normalmente un año. Una de estas series estaría medida en el sitio candidato y otra serie medida simultáneamente en un sitio de referencia. Una vez obtenido el modelo, introduciendo en el mismo los datos eólicos a largo plazo (normalmente varios años), medidos en el sitio de referencia, se estiman las series de datos eólicos a largo plazo en el sitio candidato.

Los datos eólicos pueden agruparse según otros factores como puede ser la dirección del viento en el sitio de referencia. De esta forma se pueden establecer sectores de dirección de tamaño generalmente de 30º o 45º formándose así doce u ocho, respectivamente . En este caso se obtiene un modelo por cada uno de los sectores de dirección. Con estos modelos se puede estimar los datos a largo plazo a partir de los datos eólicos en el sitio de referencia.

Muchos son los métodos que se podrían englobar en este tipo algoritmos para la estimación de las características eólica de un emplazamiento candidato. A continuación se enumeran algunos de ellos:

1. Método de Derrick [12]
2. Método de Niesel et al [11]
3. El Método Weibull Scale (WSM) [72].
4. Método de Mortimer [139]
5. Método de Rogers et al (Variance Ratio Method) [9]
6. Método de García-Rojo [16]
7. Método de Riedel et al [13]
8. Método de Landberg and Mortenson [136]
9. Método de Woods and Watson [14]
10. Método de Vermeulen et al [138]
11. Método de Joensen et al [135]

En los puntos sucesivos de este capítulo se hará una breve descripción de aquellos más utilizados en los trabajos de investigación publicados relativos a la estimación de datos eólicos a largo plazo.

6.2. Método de Derrick

Derrick [12] usa una regresión lineal para caracterizar la relación entre las velocidades del viento del sitio candidato (c) y del sitio de referencia (r) a largo plazo (LT), (Ec 6-1).

$$\text{(Ec 6-1)} \qquad \left(v_j\right)_c^{LT} = a\left(v_j\right)_r^{LT} + b$$

$\left(v_j\right)_c^{LT}$ son las velocidades del viento estimadas en el sitio candidato, $\left(v_j\right)_r^{LT}$ son las velocidades del viento medidas en el sitio de referencia, a y b son la pendiente y la ordenada en el origen obtenidas de la regresión lineal [77], (Ec 6-2).

$$\text{(Ec 6-2)} \qquad \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^{n}\left(v_i^2\right)_r^{ST} & \sum_{i=1}^{n}\left(v_i\right)_r^{ST} \\ \sum_{i=1}^{n}\left(v_i\right)_r^{ST} & n \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n}\left(v_i\right)_c^{ST}\left(v_i\right)_r^{ST} \\ \sum_{i=1}^{n}\left(v_i\right)_c^{ST} \end{bmatrix}$$

En la (Ec 6.2), $\left(v_i\right)_r^{ST}$ y $\left(v_i\right)_c^{ST}$ son las velocidades medias horarias del viento a corto plazo (ST) en el sitio de referencia y en el sitio candidato, respectivamente. *n* es el número de datos de velocidad del viento.

Generalmente, el MCP agrupa la velocidades del viento horarias en función de la dirección en el sitio de referencia. Para ello, los datos son divididos en un determinado número de sectores de dirección, que normalmente son ocho de 45º o 12 de 30º. Entonces se estiman los parámetros *a* y *b* del modelo, (Ec 6-2), para cada sector de dirección. Es decir, *a* y *b* dependen de la velocidad del viento y de la dirección. Por tanto, *n* en la (Ec 6-2), es el número de datos de velocidades de viento en el sector de dirección del sitio de referencia que se esté analizando.

6.3. Método de Niesel et al

Niesel et al. [11] proponen descomponer las velocidades del viento del sitio de referencia y del candidato según dos ejes cartesianos (x,y) [107] y llevar a cabo una regresión bidimensional, (Ec 6-3).

(Ec 6-3)
$$\begin{bmatrix} \left\{ (v_x)_i \right\}_c^{LT} \\ \left\{ (v_y)_i \right\}_c^{LT} \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} \left\{ (v_x)_i \right\}_r^{LT} \\ \left\{ (v_y)_i \right\}_r^{LT} \end{bmatrix}$$

Los coeficientes a_{ij} y b_j se determinan usando una regresión lineal, separadamente para los distintos sectores de dirección de la velocidad del viento que se consideren. Es decir, para cada sector se estiman los coeficiente mediante el producto matricial indicado en la (Ec 6- 4)

$$\begin{bmatrix} b_1 & b_2 \\ a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} n & \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_r^{ST})_x \right\}_i^{2} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \left\{ (v_x)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i^2 \right\}_r^{ST} \end{bmatrix}^{-1}$$

(Ec 6-4)

$$\begin{bmatrix} \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \left\{ (v_x)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} \left\{ (v_y)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \left\{ (v_y)_i \right\}_r^{ST} \end{bmatrix}$$

Los módulos de cada una las velocidades estimadas a largo plazo en la estación candidata se determinan mediante (Ec 6- 5)

(Ec 6-5) $$\left(v_i\right)_c^{LT} = \left[\left\{\left(v_x\right)_i^2\right\}_c^{LT} + \left\{\left(v_y\right)_i^2\right\}_c^{LT}\right]$$

Las direcciones a largo plazo pueden obtenerse a partir de las componentes según los ejes x e y de las velocidades estimadas a largo plazo haciendo uso de la (Ec 6-5). [107]

6.4. Método de García Rojo

El procedimiento usado por García-Rojo [16] se basa en el cálculo de la función de densidad de probabilidad $p_{c-r}^{ST}(v_c, d_c, v_r, d_r)$ de la velocidad (*v*) y dirección (*d*) del viento a corto plazo (*ST*) del sitio candidato (*c*) y del sitio de referencia (*r*).

A partir de la función de densidad de probabilidad (JPMF, de su traducción al inglés, Joint Probabilistic Mass Function) a corto plazo y de la función de densidad de probabilidad de la velocidad y dirección del viento a largo plazo en el sitio de referencia, $p_r^{LT}(v,d)$, se estima la función de densidad de probabilidad de la velocidad y dirección del viento a largo plazo (*LT*) en el sitio candidato, $p_c^{LT}(v,d)$ (Ec 6-6).

(Ec 6-6) $$p_c^{LT}(v_i, d_j) = \frac{1}{NF}\sum_{k=1}^{Nw}\sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)$$

Donde *NF* es un factor de normalización[1], (Ec 6-7)

(Ec 6-7) $$NF = \sum_{i=1}^{Nw}\sum_{j=1}^{Nd}\sum_{k=1}^{Nw}\sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)$$

Nw y *Nd* son los números de bines de velocidad y dirección del viento de la JPMF.

La función de densidad de probabilidad marginal para los *Nw* bines puede obtenerse a partir de la (Ec 6-8),

(Ec 6-8) $$p_c^{LT}(v_i) = \frac{1}{NF}\sum_{j=1}^{Nd}\sum_{k=1}^{Nw}\sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)\,; \qquad i = 1\ldots Nw$$

[1] En la referencia [711] no se incluye dicho factor. Probablemente, debido a una errata.

6.5. Método de Rogers et al (Variance Ratio Method) [9]

Partiendo de la base de la utilización de la expresión de la regresión lineal, la estimación de los valores de la estación candidata a partir de los datos de la estación de referencia se puede expresar según (Ec 6- 9)

(Ec 6-9) $$\hat{V}_c = m \times V_r + b$$

Donde:

$\hat{V}_c^{LT}$,es la velocidad media horaria estimada en la estación candidata

V_r^{LT} , es la velocidad media horaria observada en la estación de referencia

Aplicando a la ecuación 6-9 la varianza y la media de los datos estimados, se obtienen las ecuaciones 6-10 y 6-11

(Ec 6-10) $$\sigma^2\left(\hat{V}_c\right) = \sigma^2\left(m \times V_r + b\right) \Rightarrow m = \frac{\sigma\left(\hat{V}_c\right)}{\sigma\left(V_r\right)}$$

Donde:

$\sigma\left(\hat{V}_c\right)$, es la Desviación Estándar de los valores estimados en la estación candidata

$\sigma\left(V_r\right)$, es la Desviación Estándar de los valores observados en la estación de referencia

(Ec 6-11) $$\mu\left(\hat{V}_c\right) = \mu\left(m \times V_r + b\right) \Rightarrow b = \overline{\hat{V}_c} - \frac{\sigma\left(\hat{V}_c\right)}{\sigma\left(V_r\right)} \times \overline{V_r}$$

Donde :

$\overline{\hat{V}_c}$, es la velocidad media de los valores estimados en la estación candidata

$\overline{V_r}$, es la velocidad media de los valores observados en la estación de referencia

Si se fuerza a que la desviación estándar y la velocidad media de los valores estimados y observados en la estación candidata, para el periodo de tiempo coincidente entre la estación de referencia y candidata, sean iguales (Ec 6-12)

(Ec 6-12)
$$\sigma\left(\hat{V}_c\right) = \sigma\left(V_c\right)$$
$$\overline{\hat{V}_c} = \overline{V_c}$$

La ecuación 6-9 quedaría de la forma:

(Ec 6-13)
$$\hat{V}_c = \underbrace{\frac{\sigma\left(V_c\right)}{\sigma\left(V_r\right)}}_{a} \times V_r + \underbrace{\left(\overline{V_c} - \frac{\sigma\left(V_c\right)}{\sigma\left(V_r\right)} \times \overline{V_r}\right)}_{b}$$

La ecuación 6.13 representa el modelo del VRM, que relaciona los valores estimados de la estación candidata ($\hat{V}_c$) con los valores observados en la estación de referencia (V_r). Donde, a y b son los parámetros del modelo. Éste será el que se utilice para estimar los datos eólicos a largo plazo.

6.6. El Método Weibull Scale (WSM).

Este método empírico parte de la hipótesis de que las velocidades del viento en el sitio de referencia y en el candidato siguen una distribución de Weibull de dos parámetros, cuya función de densidad de probabilidad (en su traducción al inglés, probability density function – pdf -), W-pdf [72], viene dada por (Ec. 6-14)

(Ec 6-14)
$$f(v;\alpha,\beta) = \frac{\alpha}{\beta}\left(\frac{v}{\beta}\right)^{\alpha-1} \exp\left[-\left(\frac{v}{\beta}\right)^{\alpha}\right]$$

Además, se considera la existencia de una relación lineal entre los parámetros de escala (β) por un lado, y de los de forma (α) por otro, de las funciones de densidad de probabilidad del sitio candidato y del de referencia, (Ec. 6-15)

$$\text{(Ec 6-15)} \quad \frac{\lambda_c^{ST}}{\lambda_r^{ST}} = \frac{\lambda_c^{LT}}{\lambda_r^{LT}} \quad \Rightarrow \quad \lambda_c^{LT} = \frac{\lambda_c^{ST}}{\lambda_r^{ST}} \lambda_r^{LT}$$

En la Ec. 6-15, λ representa al parámetro de escala o de forma que se esté considerando.

6.7. Nuevo Método MCP propuesto en la presente tesis

En este punto se propone un nuevo método probabilístico de Measure-Correlate-Predict (MCP) para estimar las características de la velocidad del viento a largo plazo en un emplazamiento candidato. El método que se propone utiliza la función de densidad de probabilidad de la velocidad del viento en el sitio candidato condicionada a la velocidad del viento en el sitio de referencia. Una distribución bivariable tipo contingencia con distribución marginal especificada ha sido utilizada para tal propósito [140-141].

Sean V_c^{ST} y V_r^{ST} dos variables aleatorias que representan la velocidad del viento a corto plazo en el sitio de candidato y en el de referencia, respectivamente. Si existe y se conoce la función de densidad conjunta de probabilidad $f_{cr}^{ST}(v_c, v_r)$, la función de densidad de probabilidad condicional de la variable aleatoria V_c^{ST}, representada por $f_c^{ST}(v_c | v_r)$, para un valor v_r de V_r^{ST}, viene definida por (Ec 6-16) [143].

$$\text{(Ec 6-16)} \quad f_c^{ST}(v_c | v_r) = f_{c-r}^{ST}(v_c, v_r) \big/ f_r^{ST}(v_r)$$

Donde $f_r^{ST}(v_r)$ es la función de densidad de probabilidad de V_r^{ST} de manera tal que $f_r^{ST}(v_r) > 0$.

En el método propuesto, a partir de la función de densidad de probabilidad condicional a corto plazo, (Ec 6-16), y de la función de densidad de probabilidad a largo plazo en el sitio de referencia, $f_r^{LT}(v)$, se estima la función de densidad de probabilidad a largo plazo en el sitio candidato, $f_c^{LT}(v)$, (Ec 6-17).

(Ec 6-17) $$f_c^{LT}(v_c) = \frac{1}{CNF}\int_0^\infty f_c^{ST}(v_c|v_r)\, f_r^{LT}(v_r)dv_r$$

Donde CNF es un factor de normalización, (Ec 6-18)

(Ec 6-18) $$CNF = \int_0^\infty\int_0^\infty f_c^{ST}(v_c|v_r)\, f_r^{LT}(v_r)dv_r dv_c$$

Existen diferentes métodos para la construcción de distribuciones bivariables a partir de la forma de distribuciones marginales. En el estudio que se realiza en el presente capítulo se han utilizado la familia de distribuciones propuestas por Plackett [140,141], las cuales se denominan distribuciones tipo c (del inglés, contingency-type o simplemente c-type).

Por tanto la (Ec 6-16) puede escribirse como se indica en (Ec 6-19)

(Ec 6-19) $$f_c^{ST}(v_c|v_r) = \frac{1}{2\sqrt{S2}}\, f_c^{ST}(v_c)\left\{\frac{(\psi-1)\left[S1-2\psi F_c^{ST}(v_c)\right]\left[S1-2\psi F_r^{ST}(v_r)\right]}{S2}+\psi+1\right\}$$

Donde, S1 viene dado por (Ec 6-20) y S2 por (Ec 6-21).

(Ec 6-20) $$S1 = 1+\left[F_c^{ST}(v_c)+F_r^{ST}(v_r)\right](\psi-1)$$

(Ec 6-21) $$S2 = S1^2 - 4\psi(\psi-1)F_c^{ST}(v_c)F_r^{ST}(v_r)$$

En las ecuaciones anteriores, $F_c^{ST}(v_c)$ y $F_r^{ST}(v_r)$ son las distribuciones de frecuencia acumulada (cdf). $f_c^{ST}(v_c)$ es la función de densidad de probabilidad (pdf) en el sitio candidato. ψ es el coeficiente de asociación. Éste debe ser estimado. En este estudio para estimar ψ igualamos el coeficiente de correlación de la muestra de datos de las estaciones candidata y de referencia, al coeficiente de correlación del modelo [140,141].

El coeficiente de correlación del modelo a corto plazo, ζ^{ST}, viene dado por (Ec 6-22).

(Ec 6-22) $$\xi^{ST} = \frac{E(v_c,v_r)-E(v_c)E(v_r)}{\sigma_c\sigma_r}$$

Donde los valores estimados, *E*, vienen dados por la (Ec 6-23) y las varianzas σ_c^2 y σ_r^2 por la (Ec 6-24).

(Ec 6-23) $$E(v_c v_r) = \int_0^\infty \int_0^\infty v_c v_r f_{cr}^{ST}(v_c, v_r) dv_c dv_r \quad ; \quad E(v_c) = \int_0^\infty v_c f_c^{ST}(v_c) dv_c \quad ;$$

$$E(v_r) = \int_0^\infty v_r f_r^{ST}(v_r) dv_r$$

(Ec 6-24) $$\sigma_c^2 = \int_0^\infty \left(v_c - E(v_c)\right)^2 f_c^{ST}(v_c) dv_c \ ; \ \sigma_r^2 = \int_0^\infty \left(v_r - E(v_v)\right)^2 f_r^{ST}(v_r) dv_r$$

El coeficiente de correlación de la muestra, $\hat{r}$ puede calcularse a partir de los n-valores de la muestra ($v_{c,i}, v_{r,i}$), según la (Ec 6-25).

(Ec 6-25) $$\hat{r} = \frac{n\sum_{i=1}^{n} v_{c,i} v_{r,i} - \left(\sum_{i=1}^{n} v_{c,i}\right)\left(\sum_{i=1}^{n} v_{r,i}\right)}{\left[n\sum_{i=1}^{n} v_{c,i}^2 - \left(\sum_{i=1}^{n} v_{c,i}\right)^2\right]^{\frac{1}{2}} \left[n\sum_{i=1}^{n} v_{r,i}^2 - \left(\sum_{i=1}^{n} v_{r,i}\right)^2\right]^{\frac{1}{2}}}$$

La (Ec 6-24) se iguala a (Ec 6-25) y el método de Secant/Mueller [144] se utiliza para calcular ψ.

CAPITULO 7

El potencial eólico en Canarias. Información eólica de partida utilizada en la tesis

INDICE

7. EL POTENCIAL EOLICO EN CANARIAS. INFORMACION EOLICA DE PARTIDA UTILIZADA EN LA TESIS 163

7.1. Características generales del viento en Canarias. 163

7.2. Información eólica de partida utilizada en la presente tesis 166

7.2.1 Exposición de los Estadísticos principales de la información eólica disponible ... 168

7. EL POTENCIAL EOLICO EN CANARIAS. INFORMACION EOLICA DE PARTIDA UTILIZADA EN LA TESIS

7.1. Características generales del viento en Canarias.

El clima de las islas canarias está condicionado por dos factores de carácter general: su condición de islas y su situación geográfica en las proximidades del trópico de Cáncer. Es la presencia del mar lo que hace que el clima de Canarias sea muy diferente del que le correspondería por su latitud de extrema sequedad.

Uno de los factores particulares que influye en el clima del archipiélago canario son los vientos alisios. Son unos vientos regulares y moderados, cálidos y secos en origen pero que al atravesar el océano se cargan de humedad y se refrescan. Se originan en una zona próxima a las islas Azores. En verano es cuando las islas Canarias se encuentran bajo la influencia plena de los mismos. En invierno la influencia es menor porque el régimen de los vientos alisios puede ser alterado por otras perturbaciones del clima. Tienen dos componentes: uno superficial, el alisio inferior, que sopla del nordeste entre el nivel del mar y los 1500 metros de altitud, y que se presenta como un viento húmedo y fresco. Por encima del primero sopla el alisio superior, que tiene dirección noroeste; es un viento seco y relativamente cálido [146]. Debido a que el alisio superior es seco y cálido, actúa como un techo y no deja escapar la humedad del alisio inferior; se forma así una condensación de la humedad, nubes que no producen lluvias ni pueden escapar (Figura 7.1). Esto es lo que se llama el mar de nubes y sólo se encuentra en la cara norte de las islas más altas (las que superan los 1500 metros de altitud).

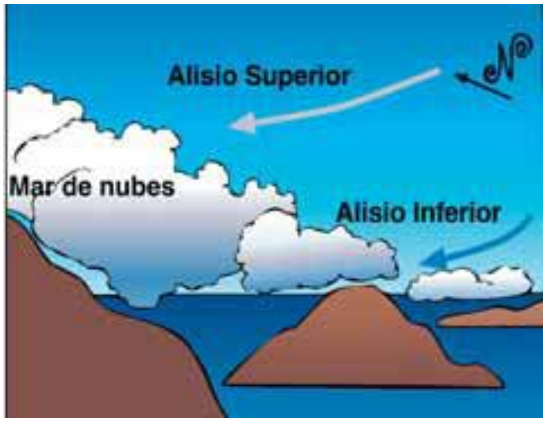

Figura 7.1: Características generales del viento en Canarias

Los alisios varían en intensidad en relación al desplazamiento que sufre el anticiclón de las Azores a lo largo del año. Durante el verano, gran parte de la primavera, y aún en parte del otoño, la frecuencia del régimen de alisios es muy alta, siendo del 90 al 95% del tiempo durante el verano[1] (Figura 7.2).

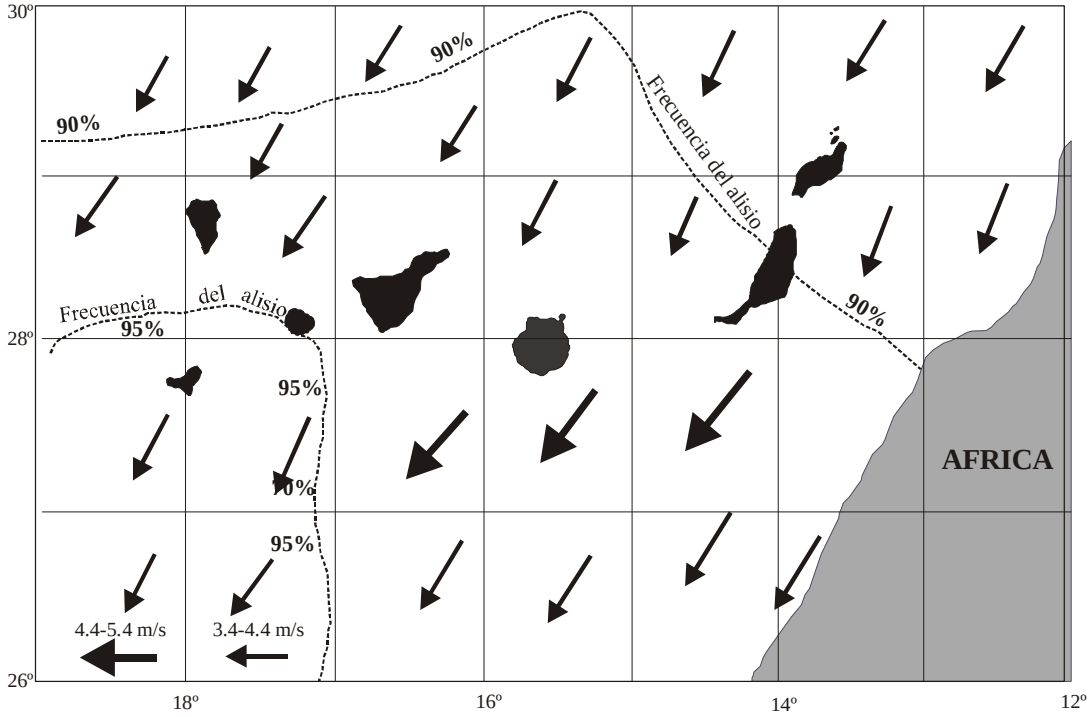

Figura 7.2: Frecuencia de los vientos alisios en verano

En el invierno[2], el límite septentrional de la región de los alisios baja de latitud, pero aún quedan las islas Canarias dentro de esta zona de régimen de vientos, aunque cerca de su límite superior. En esta estación su frecuencia sólo llega al 50% (Figura 7.3).

[1] En verano, el anticiclón se sitúa más lejos de Canarias, en las Azores, por lo que la acción de los alisios es más intensa.
[2] En invierno, el anticiclón sitúa su núcleo muy cerca de Canarias, en Madeira, por lo que la acción de los alisios es menos importante.

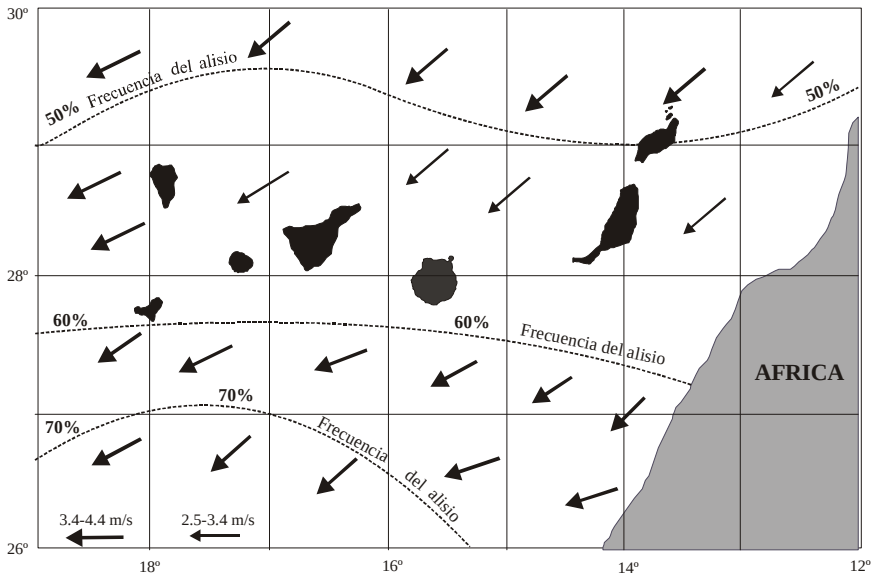

Figura 7.3: Frecuencia de los vientos alisios en invierno

Estos vientos alisios, al ser muy regulares y de velocidad media moderada, son ideales para el aprovechamiento de la energía eólica [147].

Además de los vientos alisios soplan en el Archipiélago otros vientos, no constantes pero de una cierta regularidad local: Los vientos saharianos del Este, los vientos marítimos polares del Norte y los vientos tropicales del Sur.

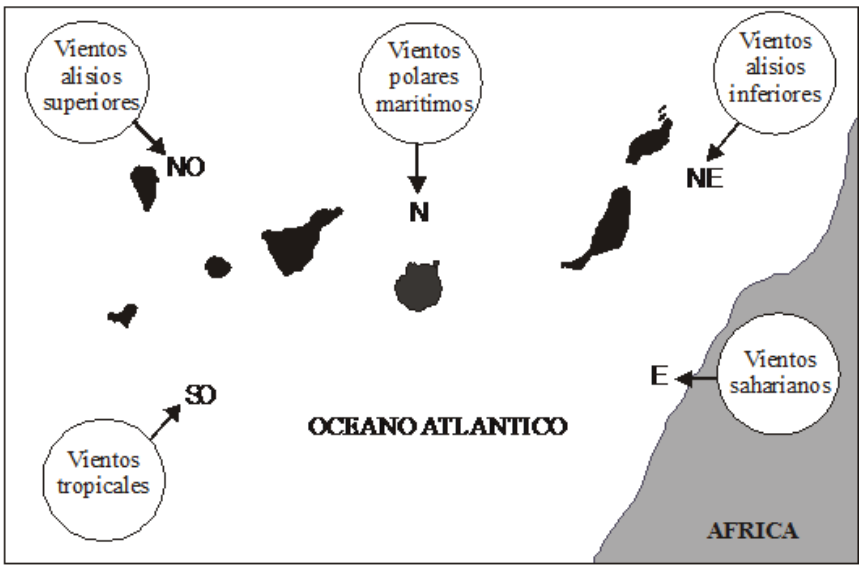

Figura 7.4: Direcciones predominantes de los vientos típicos del Archipiélago

En los vientos de componente Sur, y fundamentalmente Este, procedentes del Sahara, secos, calientes y cargados de polvo (calima) se pueden distinguir dos tipos principales: Los vientos saharianos en niveles bajos y en niveles altos. Los primeros se producen por el debilitamiento o alejamiento del anticiclón de las Azores, y su influencia es escasa sobre el Archipiélago Canario. Suelen aparecer en otoño y primavera, cuando un anticiclón se sitúa sobre el norte de África o sur de Europa. La masa de aire recorre la superficie del desierto disminuyendo su humedad y aumentando su temperatura, alcanza posteriormente las costas atlánticas africanas, adentrándose en el Océano Atlántico y llegando hasta Canarias. Los vientos saharianos de niveles altos se producen durante los meses más cálidos del verano. En esta situación el Sol calienta la superficie del desierto. Esta masa de aire seco y muy cálido asciende a cotas más alta, provocando la presencia de una borrasca seca sobre el Sahara. Al alcanzar los niveles altos, sobre los 500 m. de altitud, la masa de aire se dirige hacia el Oeste, alcanzando las medianías y cumbres altas del Archipiélago Canario.

El viento marítimo polar se produce por la presencia de una fuerte borrasca a latitudes de 40ºN, o a que el Anticiclón de las Azores se hace más extenso y su centro alcanza latitudes superiores. En ambos casos una masa de aire frío proveniente de latitudes altas y con extenso recorrido sobre el Atlántico, alcanza el Archipiélago Canario. Estas advenciones de aire frío de componentes Norte y Noroeste, dejan sentir su efecto en invierno y se notan mucho más entre los 1500 y 2000 metros que al nivel del mar [148].

Los vientos tropicales de componente Suroeste y Oeste se producen por la llegada de borrascas atlánticas provenientes del sur de Azores. Actúan sobre todo en épocas invernales, provocando abundantes lluvias, especialmente, en las zonas altas de la vertiente meridional; aunque pueden transcurrir varios años sin que hagan acto de presencia en Canarias.

7.2. Información eólica de partida utilizada en la presente tesis

Los datos eólicos utilizados en la presente tesis se corresponden con los recopilados para diferentes emplazamientos ubicados en las diferentes islas del Archipiélago Canario. Concretamente se ha trabajado con cuarenta (40) estaciones meteorológicas.

En la tabla 7.1 se han expuesto diferentes datos generales de las mismas: El código asignado a cada una de ellas, la isla en la que se encuentra, sus coordenadas geográficas, estadísticos medios de la velocidad, etc.

Tabla 7.1: Datos generales de las estaciones meteorológicas

ID	CODIGO ESTACION	ISLA	Altura estación	Latitud (N)	Longitud (W)	Altitud (m)	Velocidad Media Anual (m/s)	Desviación típica Anual (m/s)
1	GC0110	GRAN CANARIA	10	27º55'44"	15º23'20"	16	7,14	3,72
2	GC0210	GRAN CANARIA	10	27º56'46"	15º23'6"	9	6,06	3,01
3	GC0310	GRAN CANARIA	10	27º56'40"	15º22'9"	7	11,59	5,55
4	GC0410	GRAN CANARIA	10	27º51'36"	15º23'13"	3	6,88	3,64
5	GC0510	GRAN CANARIA	10	27º51'7"	15º24'29"	7	6,11	3,60
6	GC0520	GRAN CANARIA	20	27º51'7"	15º24'29"	7	7,07	3,67
7	GC0613	GRAN CANARIA	13	28º9'14"	15º31'44"	15	3,53	2,32
8	GC0720	GRAN CANARIA	20	28º7'30"	15º40'37"	472	7,80	3,82
9	GC0710	GRAN CANARIA	10	28º7'30"	15º40'37"	472	7,59	3,83
10	GC0820	GRAN CANARIA	20	28º9'47"	15º42'25"	56	8,79	3,96
11	GC0815	GRAN CANARIA	15	28º9'47"	15º42'25"	57	8,21	3,97
12	GC0810	GRAN CANARIA	10	28º9'47"	15º42'25"	58	8,76	3,68
13	GC0920	GRAN CANARIA	20	28º10'12"	15º38'20"	30	6,21	3,22
14	GC0910	GRAN CANARIA	10	28º10'12"	15º38'20"	30	5,89	3,08
15	GC1015	GRAN CANARIA	15	28º	15º48'47"	6	5,16	2,94
16	GC1120	GRAN CANARIA	20	27º57'36"	15º33'36"	1905	6,40	4,24
17	GC1225	GRAN CANARIA	25	27º51'47"	15º25'12"	37	6,21	3,46
18	GC1310	GRAN CANARIA	10	28º5'15"	15º29'17"	361	3,02	1,60
19	GC1410	GRAN CANARIA	10	27º53'24"	15º23'42"	3	6,32	3,30
20	GC1515	GRAN CANARIA	15	28º1'36"	15º23'17"	4	6,23	3,31
21	TF0110	TENERIFE	10	28º4'9"	16º30'27"	45	6,92	3,85
22	TF0210	TENERIFE	10	16º20'31"	28º29'12"	615	5,27	2,68
23	TF0310	TENERIFE	10	28º6'36"	16º29'6"	79	5,35	3,66
24	TF0410	TENERIFE	10	28º25'12"	16º21'18"	732	6,20	5,13
25	FU0420	FUERTEVENTURA	20	28º36'48"	13º50'55"	115	6,33	2,69
26	FU0410	FUERTEVENTURA	10	28º36'48"	13º50'55"	115	5,81	2,56
27	FU0510	FUERTEVENTURA	10	28º32'54"	13º52'49"	207	5,73	2,70
28	FU0520	FUERTEVENTURA	20	28º32'54"	13º52'49"	207	6,15	3,27
29	FU0110	FUERTEVENTURA	10	28º27'10"	13º51'54"	24	5,83	2,53
30	FU0217	FUERTEVENTURA	17	28º44'48"	13º52'29"	6	6,54	3,06
31	FU0318	FUERTEVENTURA	18	28º26'26"	13º52'56"	55	5,51	2,79
32	FU0310	FUERTEVENTURA	10	28º26'26"	13º52'56"	55	4,63	2,47
33	LP0110	LA PALMA	10	28º36'47"	17º45'36"	85	4,82	2,28
34	HI0110	HIERRO	10	27º47'39"	17º54'43"	480	9,44	5,71
35	LZ0110	LANZAROTE	10	28º57'7"	13º36'	10	5,82	3,00
36	GC1610	GRAN CANARIA	10	15º35'53"	27º44'7"	1	3,56	2,47
37	TF0510	TENERIFE	10	28º2'35"	16º34'16"	51	5,64	3,16
38	HI0210	HIERRO	10	27º48'50"	17º53'10"	30	5,96	2,85
39	GO0110	GOMERA	10	28º04'51"	17º06'10"	0	3,39	2,18
40	TF0610	TENERIFE	10	28º27'18"	16º14'56"	0	1,92	1,30

Las velocidades medias anuales del total de las estaciones abarcan un amplio rango de datos, desde los 1,92 m/s (TF0610) a los 11,59 m/s (GC0310)

La información eólica utilizada ha sido cedida por la Agencia Estatal de Meteorología (AEMET) del Ministerio de Medio Ambiente, y Medio Rural y Marino del Gobierno de España y por el Instituto Tecnológico de Canarias (ITC), empresa perteneciente al Gobierno de Canarias. Ambas empresas tienen contrastada experiencia en la adquisición y tratamiento de datos meteorológicos, por lo que queda perfectamente acreditada la fiabilidad de la información aportada.

Los datos meteorológicos aportados se corresponden con medias horarias de los parámetros de velocidad y dirección del viento. Los años de medición abarcan desde 1997 al 2008, disponiéndose para cada estación de un número de años determinados dentro del rango anterior.

7.2.1 Exposición de los Estadísticos principales de la información eólica disponible

En la tabla 7.2 se han marcado los años de los que se dispone información para cada una de las estaciones. En total se ha trabajado con un total de 2.698.080 datos.

Tabla 7.2: Años disponibles para cada estación meteorológica

ID	CODIGO ESTACION	AÑOS											
		1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	GC0110												
2	GC0210												
3	GC0310												
4	GC0410												
5	GC0510												
6	GC0520												
7	GC0613												
8	GC0720												
9	GC0710												
10	GC0820												
11	GC0815												

ID	CODIGO ESTACION	AÑOS											
12	GC0810												
13	GC0920												
14	GC0910												
15	GC1015												
16	GC1120												
17	GC1225												
18	GC1310												
19	GC1410												
20	GC1515												
21	TF0110												
22	TF0210												
23	TF0310												
24	TF0410												
25	FU0420												
26	FU0410												
27	FU0510												
28	FU0520												
29	FU0110												
30	FU0217												
31	FU0318												
32	FU0310												
33	LP0110												
34	HI0110												
35	LZ0110												
36	GC1610												
37	TF0510												
38	HI0210												
39	GO0110												
40	TF0610												

En la tabla 7.3 se han expuesto las velocidades medias anuales para cada una de las estaciones.

Tabla 7.3: Velocidades medias anuales en las estaciones meteorológicas

ID	CODIGO ESTACION	VELOCIDAD MEDIA (m/s)											
		1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
1	GC0110			7,15	6,37	6,76	7,29	7,32	7,02	6,93	7,10	7,50	7,98
2	GC0210					6,35	6,11		5,72				
3	GC0310					11,59							
4	GC0410										6,88		
5	GC0510									6,19	6,03		
6	GC0520									7,19	6,95		
7	GC0613										3,53		
8	GC0720	6,95	8,28	8,37			7,67	7,58				7,95	
9	GC0710	6,65	8,01	8,21			7,51	7,33				7,85	
10	GC0820			8,85	9,02	8,51							
11	GC0815										8,21		
12	GC0810			8,70	8,83								
13	GC0920		6,78			6,10				6,12	5,86		
14	GC0910		6,44			5,72				5,79	5,61		
15	GC1015										5,16		
16	GC1120									6,10	6,61	6,50	
17	GC1225							6,31	6,29	6,17	6,08		
18	GC1310								3,02				
19	GC1410						6,36	6,30	6,30				
20	GC1515											6,23	
21	TF0110			7,09	6,83				6,85				
22	TF0210								5,27				
23	TF0310										5,35		
24	TF0410						6,26	6,14					
25	FU0420										6,33		

ID	CODIGO ESTACION	VELOCIDAD MEDIA (m/s)											
26	FU0410										5,81		
27	FU0510										5,73		
28	FU0520										6,15		
29	FU0110			6,09	5,81	5,78	5,84	5,68	5,67	5,56	5,79	5,88	6,23
30	FU0217					6,54							
31	FU0318					5,51							
32	FU0310					4,63							
33	LP0110			4,97	4,76	4,70	4,79	4,66	4,68	4,53	4,46	5,20	5,47
34	HI0110					9,44							
35	LZ0110			6,14	5,77	5,88	5,94	5,76	5,73	5,51	5,56	5,82	6,12
36	GC1610			3,48	3,30	3,34	3,70	3,30	3,70	3,80	3,60	3,50	3,87
37	TF0510			6,09	5,91	5,48	5,50	5,55	5,50	5,63	5,14	5,58	6,01
38	HI0210			6,26	5,55	5,35	5,77	5,78	5,91	5,80	6,10	6,44	6,66
39	GO0110			3,90	3,70	3,50	3,20	3,30	3,10	2,80	3,20	3,20	3,95
40	TF0610			2,10	1,67	1,77	1,99	1,98	2,02	2,00	1,98	1,66	2,06

El resultado para la velocidad media y desviación típica para cada una de las estaciones dentro de la totalidad del rango de datos disponibles, es el expresado en la tabla 7.1.

Con respecto a la dirección del viento característico en las islas canarias ya se comentó en el apartado 7.1 que eran los vientos alisios los que de forma general, y con una influencia que difería según la época estacional del año, predominaban en las islas. Este tipo de vientos se caracterizaban por tener, en cotas inferiores a los 1500m y en la latitud propia del archipiélago canario, una dirección predominante del Nordeste. Aún así también se comentó que existían otro tipo de vientos presentes fundamentalmente en Otoño e Invierno, cuyas características eólicas difería de los alisios. Por lo tanto, si bien en la distribución de frecuencia de direcciones de los vientos en el archipiélago predominan, de forma general, la dirección Nordeste, se pueden encontrar ubicaciones con diferentes regímenes de viento. A modo de ejemplo, en la figuras de la 7.5 a la 7.7 se muestran las distribuciones de frecuencias de direcciones de viento de diferentes ubicaciones, donde se aprecian características diferentes.

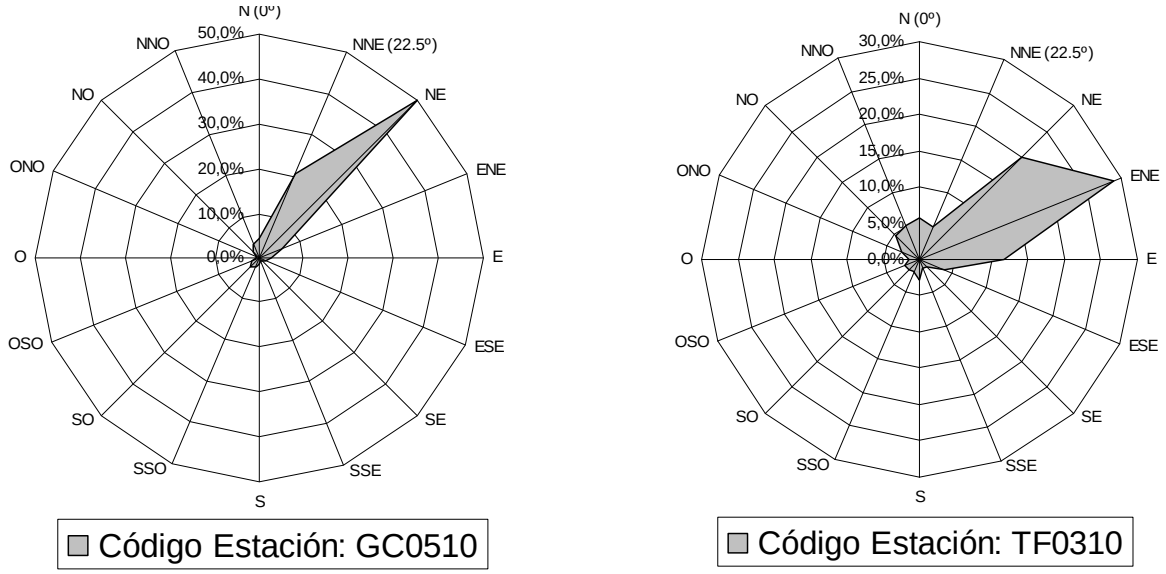

Figura 7.5: Algunos casos de emplazamientos con una distribución de frecuencia de direcciones con predominancia NE-ENE

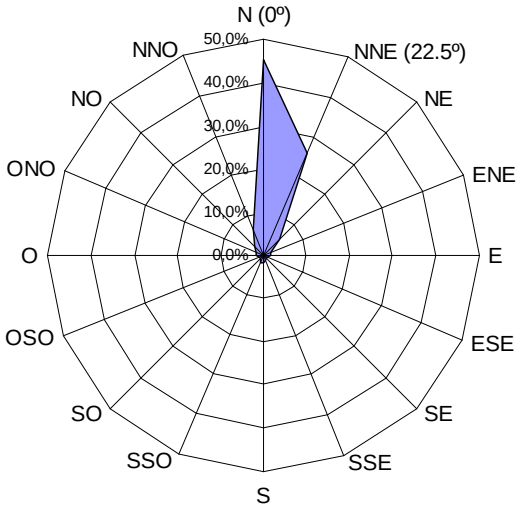

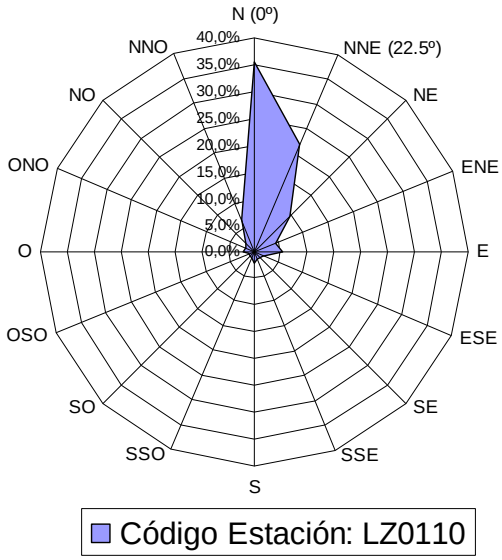

Figura 7.6: Algunos casos de emplazamientos con una distribución de frecuencia de direcciones con predominancia N-NNE

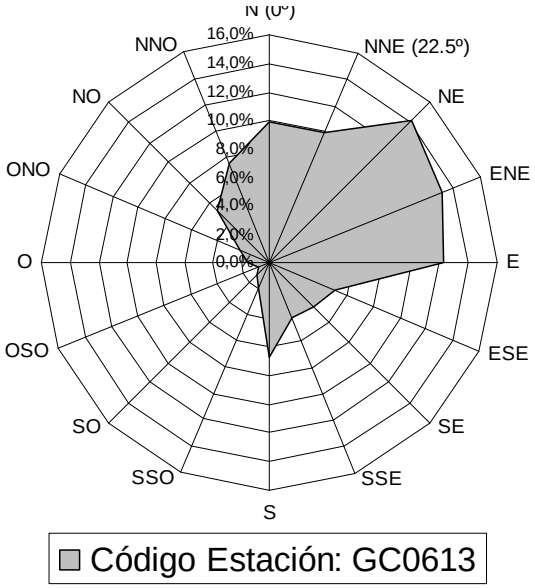

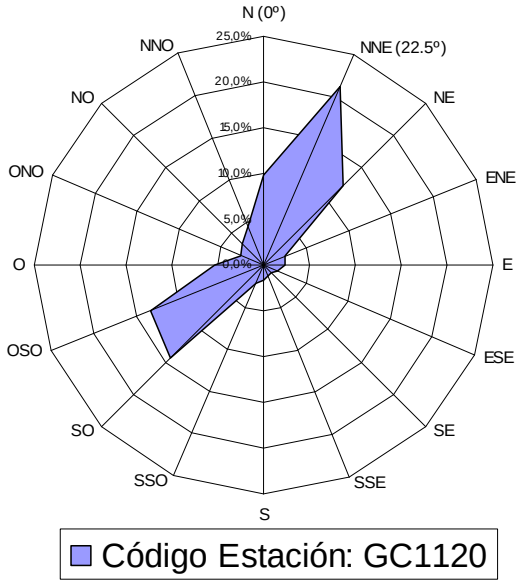

Figura 7.7: Algunos casos de emplazamientos con una distribución de frecuencia de direcciones variables

Análisis de la velocidad a largo plazo

Como se comentó en el capítulo 1, para el análisis a largo plazo se requiere un número suficiente de años de datos para que este caracterice el viento en la zona de estudio. En esta caracterización se requería un mínimo de 10 años de datos. De entre las estaciones de partida de las que se dispone, se han seleccionado 6 de ellas para el análisis de los datos de velocidad a largo plazo (Tabla 7.4).

Tabla 7.4: Estaciones seleccionada para el cálculo de las métricas observadas de velocidad a largo plazo

CODIGO ESTACION	PERIODO DE AÑOS DISPONIBLE	Nº AÑOS
GC0110	1999-2008	10
LZ0110	1999-2008	10
FU0110	1999-2008	10
TF0510	1999-2008	10
LP0110	1999-2008	10
HI0210	1999-2008	10

En la tabla 7.3 se expusieron las velocidades medias anuales para todas las estaciones meteorológicas. A partir de éstas se calculó la velocidad media anual a largo plazo, como la media de la velocidad para todo el rango de datos disponible. Para el caso particular de las seis estaciones seleccionadas, se correspondería con un periodo de 10 años. Los resultados se exponen en la Tabla 7.1.

Comparando la velocidad media anual para cada uno de los años con la velocidad media anual a largo plazo, se puede definir el error relativo medio absoluto de la velocidad media anual como:

(Ec 7-1) $$MARE_{anual} = \frac{\sum_{i=1}^{N} \frac{\left| \overline{V_i^{cp}} - \overline{V^{LP}} \right|}{\overline{V^{LP}}}}{N}$$

Donde:

N; es el número de años

$\overline{V_i^{cp}}$; Es la velocidad media anual del año i (Velocidad media a corto plazo)

$\overline{V^{LP}}$; Es la velocidad media para todo el rango de datos disponible, en este caso 10 años (Velocidad Media a Largo Plazo)

Aplicando la (Ec 7-1) a las diferentes estaciones seleccionadas para el estudio a largo plazo, los resultados obtenidos son los que se muestran en la figura 7.8.

En ésta se exponen los resultados para el error absoluto relativo medio de la velocidad media anual, así como la desviación estándar de dicho error. Los resultados se han calculado para cada una de las estaciones. El valor medio para el conjunto de éstas se ha expresado como la Media Global.

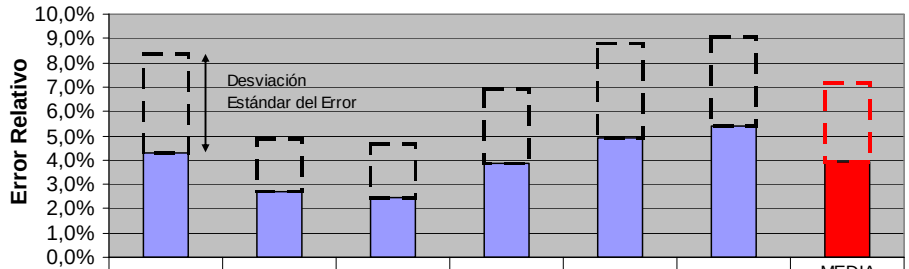

	GC0110	LZ0110	FU0110	TF0510	LP0110	HI0210	MEDIA GLOBAL
Desviación Estándar del Error	4,051%	2,130%	2,250%	3,034%	3,884%	3,654%	3,219%
Error Relativo Medio Absoluto de la Velocidad Media Anual	4,302%	2,697%	2,426%	3,894%	4,877%	5,412%	3,935%

Figura 7.8: Error absoluto relativo medio de la velocidad media anual respecto a la velocidad media a largo plazo

A partir de los resultados globales obtenidos con las seis estaciones analizadas se puede concluir, que la velocidad media anual de un año concreto se encuentra dentro del rango del ±7,2% respecto a la velocidad media a largo plazo, con una probabilidad del 95%.

A la hora de estimar la energía y compararla con la real o medida, en la mayoría de los casos, los parques eólicos deben hacer dicho análisis en términos horarios y no en términos anuales [3-5]. Por ello se hace necesario hacer una valoración del error anterior pero en términos horarios. Para ello se ha definido la velocidad media horaria a largo plazo según la (Ec 7-2). A

partir de los valores horarios a largo plazo, se puede analizar las desviaciones relativas existentes entre los valores horarios de la velocidad en un año concreto (corto plazo) y los anteriores. Mediante la ecuación 7-3 se calcula el error relativo medio absoluto de la velocidad media horaria, para cada una de las estaciones. Los resultados obtenidos se muestran en la Figura 7.9. A partir de éstos se ha calculado el valor medio del error para el conjunto de las estaciones (media global).

(Ec 7-2) $$V_i^{LP} = \frac{\sum_{j=1}^{N} V_i^{j}}{N}$$

Donde:

N; es el número de años

V_i^{j} ; Es la velocidad media de la hora i para el año j

(Ec 7-3) $$MARE_{horario} = \frac{\sum_{i=1}^{n} \frac{\left| V_i^{CP} - V_i^{LP} \right|}{V_i^{LP}}}{n}$$

Donde:

n; es el número de datos de un año

V_i^{CP} ; Es la velocidad media de la hora i de un año concreto (Velocidad media horaria a corto plazo)

V_i^{LP} ; Es la velocidad media de la hora i a largo plazo (Ec 7-2).

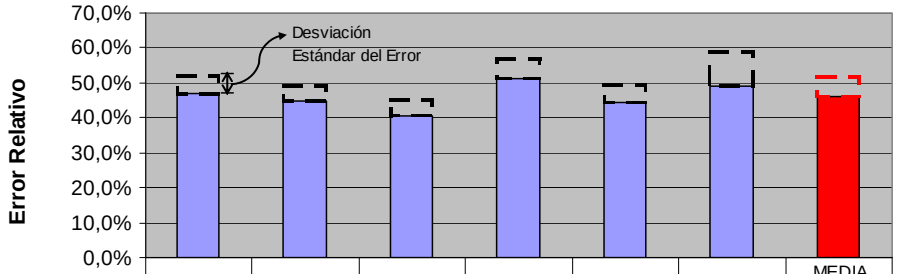

	GC0110	LZ0110	FU0110	TF0510	LP0110	HI0210	MEDIA GLOBAL
Desviación Estándar del Error	5,22%	4,56%	4,38%	5,81%	5,10%	9,53%	5,72%
Error Relativo Medio Absoluto de las velocidades medias horarias	46,79%	44,73%	40,74%	51,03%	44,24%	49,23%	46,13%

Figura 7.9: Error absoluto relativo medio de las velocidades medias horarias anuales respecto de las velocidades medias horarias a largo plazo

Considerando los resultados globales obtenidos con las seis estaciones analizadas se concluye, que la velocidad media horaria de un año concreto se encuentra dentro del rango del ±51,9% respecto a la velocidad media horaria a largo plazo, con un probabilidad del 95%.

Si se comparan estos últimos resultados con los obtenidos cuando se consideran las velocidades medias anuales (figura 7.8) se concluye, que es importante tener en cuenta los objetivos específicos de cada estudio de estimación de datos eólicos, ya que los valores obtenidos difieren en gran medida entre ambos casos.

CAPITULO 8

Evolución del aprovechamiento de la energía eólica en Canarias. Situación actual y perspectivas futuras

INDICE

8. EVOLUCION DEL APROVECHAMIENTO DE LA ENERGIA EOLICA EN CANARIAS. SITUACION ACTUAL Y PERSPECTIVAS FUTURAS 179

8.1. Introducción 179

8.2. Evolución de la contribución de la Energía Eólica al sector de la energía eléctrica en Canarias. 179

8.3. Objetivos estratégicos establecidos para el aprovechamiento de la energía eólica en Canarias 184

8.4. La ordenación del territorio canario como factor determinante en la planificación energética 186

8.5. Conclusiones 190

8. EVOLUCION DEL APROVECHAMIENTO DE LA ENERGIA EOLICA EN CANARIAS. SITUACION ACTUAL Y PERSPECTIVAS FUTURAS

8.1. Introducción

La Ley11/1997,de regulación del Sector Eléctrico Canario [161], tiene como objeto la regulación de todas las actividades relacionadas con el suministro a los consumidores de la energía eléctrica en condiciones competitivas, garantizando la seguridad de abastecimiento y logrando asegurar la regularidad en calidad y precio con especial atención al medioambiente.

En la citada Ley se establece la necesidad de la diversificación de las fuentes energéticas, lo que obliga a definir políticas de fomento de energías alternativas al objeto de reducir la vulnerabilidad de los sistemas energéticos insulares y establecer fuentes de producción energética con menor impacto sobre el medioambiente.

El fomento de la energía eólica está fundamentado sobre la base de incuestionables ventajas, tales como un menor impacto medioambiental, el coste nulo de la materia prima utilizada para la producción energética, el hecho de ser una fuente endógena de energía y de permitir aprovechar el potencial eólico de las islas, al margen de los efectos positivos que tiene sobre la economía.

Las energías renovables en general y de forma particular la energía eólica, posibilitarán la necesaria diversificación de las fuentes de energía en Canarias y aumentarán el grado de autoabastecimiento energético.

Sin embargo, los sistemas de aprovechamiento de la energía eólica para la generación de energía eléctrica (parques eólicos), son instalaciones que requieren grandes inversiones económicas (aproximadamente 1.200.000€/$MW_{instalado}$) por lo que los promotores realizan exhaustivos análisis de viabilidad económica antes de acometer este tipo de proyectos. Por otro lado requieren de grandes superficies de terreno. Si bien este tipo de instalaciones se puede compatibilizar con muchas otras actividades, se hace necesaria la planificación desde el punto de vista territorial para darle cabida dentro de la ordenación del territorio.

8.2. Evolución de la contribución de la Energía Eólica al sector de la energía eléctrica en Canarias.

A nivel nacional, la generación eléctrica ha experimentado una importante transformación desde finales de los años 90 [149], a lo que ha contribuido la progresiva penetración del gas

natural, principalmente en centrales de ciclo combinado y en cogeneración, además de las energías renovables, cuya cobertura evoluciona al alza, representando en la actualidad más del 24% de la producción eléctrica nacional (figura 8.1).

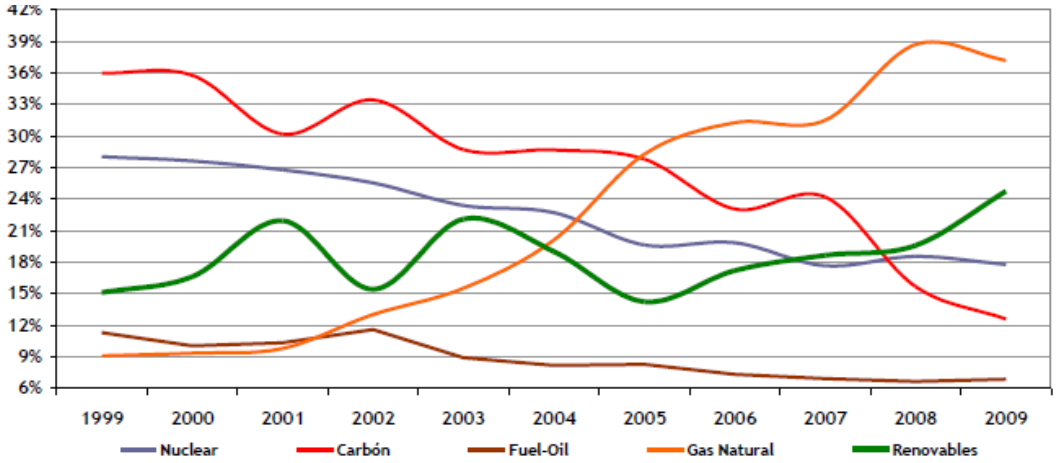

Figura 8.1: Participación de las diferentes de energía en la generación eléctrica en España [149]

Esta situación ha dado lugar a una pérdida de peso de otras fuentes energéticas como el carbón, el fuel oil, e incluso la nuclear, llegando la producción eléctrica de origen renovable a superar de manera sostenida a la producción nuclear y a la del carbón [149]. En la figura 8.2 se representa la aportación de cada fuente de energía a la producción de energía eléctrica en España a finales del año 2009.

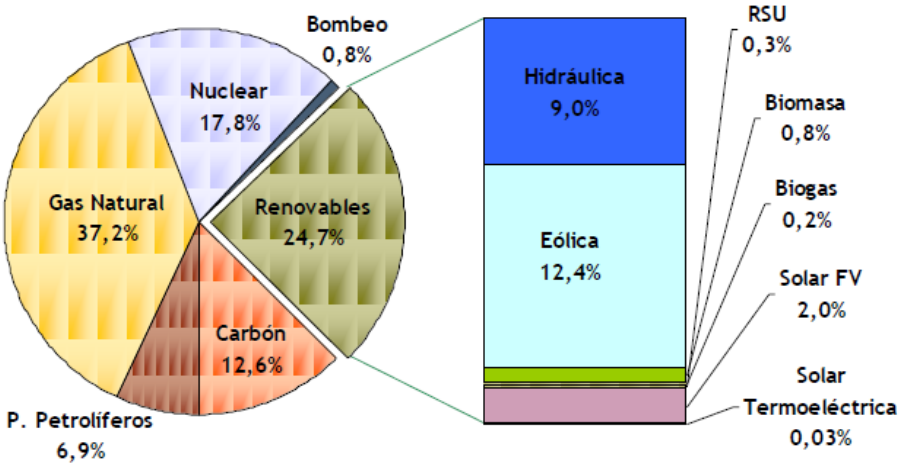

Figura 8.2: Estructura de la producción de energía eléctrica en España según su fuente primaria de procedencia. Datos de finales del año 2009 [153].

A nivel del archipiélago Canario, la evolución de la estructura de la producción de energía eléctrica según la fuente primaria de energía es la que se muestra en la figura 8.3 [150-153]. Los datos de los años 2004 al 2006 se han extraído de las estadísticas energéticas de Canarias [150-152], últimos datos oficiales publicados al respecto, mientras que los datos del año 2009 han sido extraídos del informe mensual de Red Eléctrica de España de Diciembre de 2009 [153].

Si se comparan las figuras 8.3 y 8.2, se puede observar que la estructura de producción de la energía eléctrica en el archipiélago canario difiere de la estructura media nacional. En los sistemas eléctricos canarios tiene un peso mucho mayor las fuentes derivadas del petróleo y existe una menor contribución sobre el total, de las energías renovables en general y la eólica en particular. Por otro lado, de la figura 8.3 se deduce además que la contribución de la energía eólica a la demanda de energía eléctrica del archipiélago ha permanecido prácticamente invariable en los últimos 6 años.

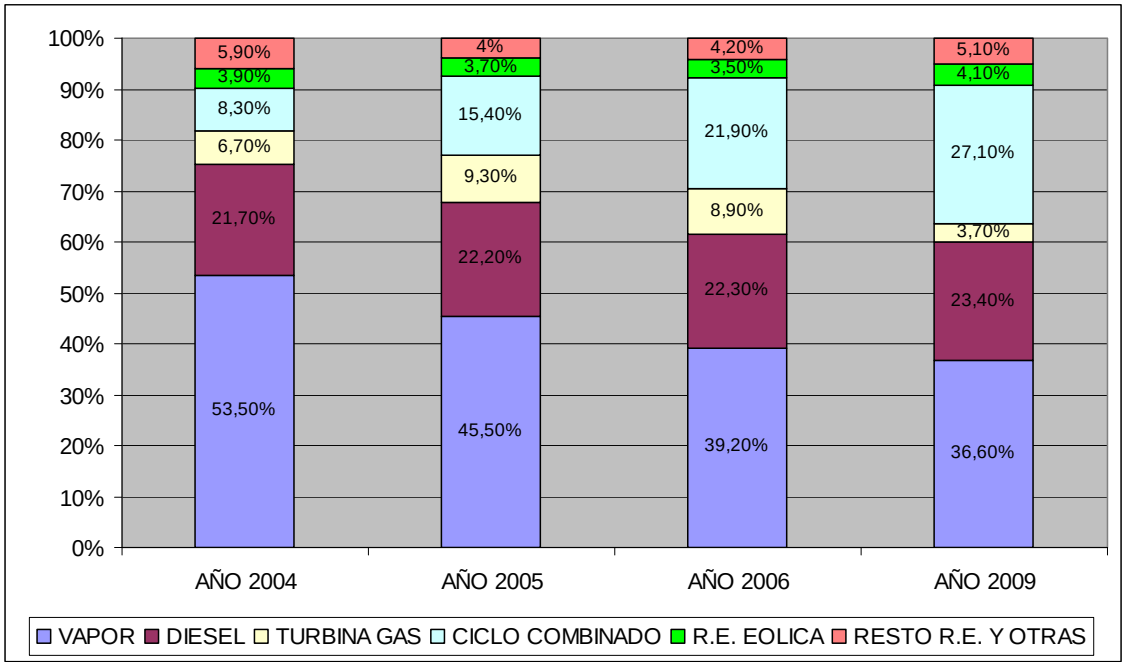

Figura 8.3: Evolución de la estructura de la producción de energía eléctrica en Canarias según su fuente primaria de procedencia [150-153].

Para el caso particular de la energía eólica, la evolución de la potencia instalada en Canarias es la que se muestra en la figura 8.4. En ésta se observa que la explosión del mercado de la energía eólica en el archipiélago data de principios de los años 90, con un crecimiento

exponencial en los primeros 6 años de dicha década. Este auge importante en un corto periodo de tiempo y en un territorio limitado y segregado como son las islas Canarias, hizo que el Gobierno de Canarias se plantease la regulación de este sector con el objeto de ordenar las infraestructuras eólicas y hacerlas compatibles con la planificación del territorio. Por ello, ideó la herramienta administrativa de los concursos eólicos. El primer concurso de asignación de potencia eólica data del año 1996 [154] en el cual se ofertaron 40,4 MW eólicos a instalar en las islas de Gran Canaria y Tenerife. Como consecuencia de la resolución de dicho concurso se observa un incremento adicional de la potencia eólica instalada durante los años 1998 al 2001. Finalmente se produce una ralentización de la potencia instalada desde el año 2002 hasta el 2009. Dentro de este periodo la potencia eólica ha crecido simplemente un 11,5% frente a un crecimiento de la potencia eléctrica total instalada en el archipiélago canario, dentro del mismo periodo, del 55,05% [152-153].

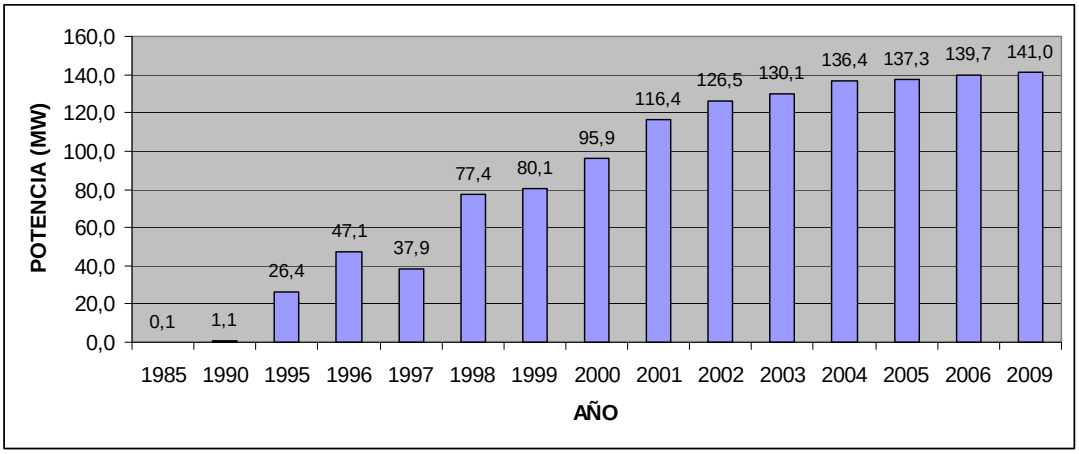

Figura 8.4: Evolución de la potencia eólica instalada en Canarias

El archipiélago canario posee zonas eólicas con alto rendimiento energético, disponiendo de parques eólicos que se encuentran entre los de mayor rendimiento a nivel mundial. Los últimos datos oficiales que se disponen sobre los rendimientos energéticos, medidos en horas equivalentes de funcionamiento (Ec 8-1), son de finales del año 2006 y publicados por la Consejería de Empleo, Industria y Comercio [155]. A modo de ejemplo cabe mencionar el Parque Eólico de Lomo Cabezo, ubicado en la Montaña de Agüimes – en el municipio de Agüimes - en la isla de Gran Canaria, con 4.183 horas equivalente en el año 2006; Parque Eólico Punta de Teno, ubicado en el municipio de Buenavista del Norte en la isla de Tenerife, con 3.828 horas equivalentes o el Parque Eólico de La Punta, ubicado en la zona de Pozo

Izquierdo – en el municipio de Santa Lucía de Tirajana – en la isla de Gran Canarias, con 3.903 horas equivalentes.

(Ec 8-1) $$Horas\ Equivalentes = \frac{Energía\ real\ producida}{Potencia\ \text{Nominal de la Instalación eólica}} \left(\frac{MWh}{MW} \right)$$

En la figura 8.5 se observa la estructura del rendimiento medio de los diferentes parques eólicos instalados en Canarias, medidos en horas equivalentes de funcionamiento año. Son datos del año 2006, últimos datos oficiales publicados. Se observa que si bien existen parques eólicos con rendimiento muy buenos, por encima de las 3500 horas equivalentes por año, también existen, en gran media, parques eólicos con menos rendimiento.

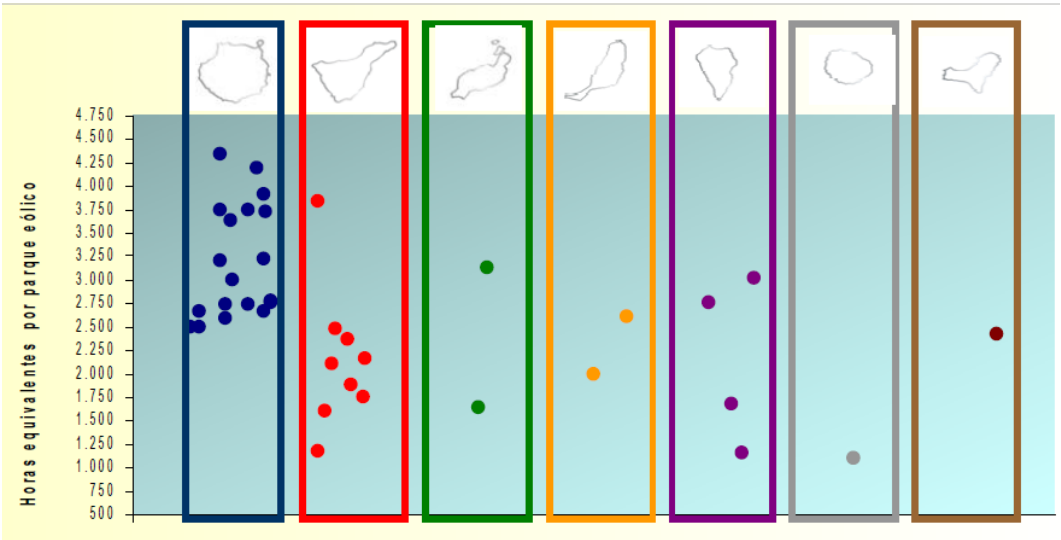

Figura 8.5: Horas equivalentes de funcionamiento de los diferentes parques eólicos instalados en Canarias. Cada punto representa el dato de un parque eólico. Año 2006 [152]

En la figura 8.6 se expone la evolución de rendimiento medio de los parques eólicos ubicados en canarias desde el año 2001 al 2006.

Islas	Horas Año 2006	Horas Año 2005	Horas Año 2004	Horas Año 2003	Horas Año 2002	Horas Año 2001
Canarias	2.748	2.764	2.836	3.003	3.067	3.057

Figura 8.6: Evolución de las horas equivalentes medias de funcionamiento de los parques eólicos existentes en el archipiélago canario [152].

Según datos publicados en el informe de Diciembre de 2009 de Red Eléctrica de España (REE) [153], la producción de energía eléctrica de origen eólico en el archipiélago canario fue de 372.248MWh. La potencia eólica instalada en ese periodo era de 141 MW [153]. Se deduce de los datos anteriores y mediante la Ec 8-1, que en el año 2009 el rendimiento medio de los parques eólicos instalados en Canarias fue de 2.640 Horas Equivalente.

De la figura 8.6 y del dato extraído para el año 2009, se concluye que ha habido una evolución decreciente del rendimiento energético de los parques eólicos instalados en Canarias. Entre los motivos de la disminución del rendimiento se encuentra el que a medida que se van ocupando las áreas con alto potencial eólico, las instalaciones han de ubicarse en zonas con potencial eólico inferior, o bien se van instalando en zonas próximas que, aún poseyendo similar potencial eólico, el rendimiento neto de los parques disminuye al aumentar el efecto estela de la zona, pérdidas de rendimiento por las sombras que se generan entre aerogeneradores [45], por una mayor concentración de aerogeneradores.

8.3. Objetivos estratégicos establecidos para el aprovechamiento de la energía eólica en Canarias

La Directiva de 2009/28/CE del Parlamento Europeo [1], relativa al fomento del uso de energía procedente de fuentes renovables, fija como objetivos generales: el conseguir una cuota del 20 % de energía procedente de fuentes renovables en el consumo final bruto de energía de la Unión Europea (UE) y una cuota del 10 % de energía procedente de fuentes renovables en el consumo de energía en el sector del transporte en cada Estado miembro para el año 2020. Para ello, establece objetivos particulares para cada uno de los Estados miembros para el año 2020 y una trayectoria mínima indicativa hasta ese año. En España, el objetivo se traduce en que las fuentes renovables representen al menos el 20% del consumo de energía final en el año 2020, mismo objetivo que para la media de la UE, junto a una contribución del 10% de fuentes de energía renovables en el transporte para ese año. Para el caso particular de la contribución de las energías renovables a la demanda de energía eléctrica establece que en España debe ser del 40%

La Directiva marca la necesidad de que cada Estado miembro redacte un Plan de Acción Nacional de Energías Renovables (PANER) para el periodo 2011-2020, con vistas al cumplimiento de los objetivos vinculantes que fija la Directiva. España ya ha elaborado su PANER 2011-2020 [149]

Dentro del ámbito de la región canaria, el documento estratégico de referencia, para la energía en general y las renovables en particular, es el Plan Energético de Canarias [156]. Los objetivos generales del Plan son los siguientes:

1. Garantizar el suministro de energía a todos los consumidores en condiciones óptimas en cuanto a regularidad, calidad y precio.
2. Potenciar al máximo el uso racional de la energía. Esto implica el minimizar su utilización manteniendo, tanto a nivel de ciudadanía en su conjunto como del sistema económico general, un nivel de satisfacción equivalente medido en términos de calidad ambiental, impactos sociales positivos y mantenimiento de la competitividad del tejido empresarial de la comunidad.
3. Impulsar la máxima utilización posible de fuentes de energías renovables, especialmente eólica y solar, como medio para reducir la vulnerabilidad exterior del sistema económico y mejorar la protección del medio ambiente.
4. Integrar la dimensión medioambiental en todas las decisiones energéticas coadyuvando a progresar en el camino hacia un crecimiento sostenible de la Región.

Dentro de los objetivos específicos que establece el Plan Energético de Canarias [156], se tiene:

- Que la contribución de las energías renovables a la demanda de energía eléctrica en el año 2015 ha de ser del 30%
- Que la potencia eólica instalada en el horizonte temporal del documento (año 2015) ha de ser de 1025MW

El PECAN es un documento elaborado anteriormente a la nueva Directiva 2009/28/CE [1], por lo que en su momento deberá adaptarse la nuevas exigencias que se marcan en dicho documento.

Si se hace una comparativa entre los objetivos estratégicos que se han marcado para el ámbito de las energías renovables en general y la eólica en particular, visto en el presente apartado, con la situación existente a finales del año 2009 en el archipiélago canario, analizado en el apartado anterior, se tiene que:

1. A nivel nacional, a finales de 2009 la contribución de las energías renovables a la producción de energía eléctrica era del 22,7%. El objetivo establecido para el año 2020 es del 40% [1]
2. En el archipiélago canario, A finales de 2009 la contribución de las energías renovables a la producción de energía eléctrica era del 9,2% (4,1% procedente de la energía eólica). El objetivo establecido por el PECAN [156] para el año 2015 es del 30%. Este objetivo estratégico debería ser revisado al alza con los nuevos objetivos marcado en la Directiva 2009/28 [1]
3. La Potencia Eólica instalada en Canarias a finales del año 2009 era de 141MW; el objetivo para el 2015 es tener instalados 1025MW [156].

De los datos expuestos anteriormente se deduce que hay un gran camino que recorrer en el archipiélago canario, para cumplir con los objetivos establecidos. Concretamente para el caso particular de la potencia eólica y con referencia el año 2009 quedarían por instalar 884MW.
En Abril del 2007, el Gobierno de Canarias publicó dos nuevos concursos de asignación de potencia eólica. Uno relativo a parque eólicos con consumos asociados [157] y el otro relativo a parques eólicos que vierten toda su energía a la red eléctrica [158]. En total la potencia eólica ofertada fue de 45 y 440MW, respectivamente. Las instalaciones a las que se le asignó potencia eólica en los mencionados concursos están en fase de las autorizaciones administrativas, previéndose que comiencen a instalarse durante el año 2011. Aún así, una vez instaladas toda la potencia asignada en el último concurso, quedarían 399MW por asignar en potenciales concursos posteriores para cumplir el objetivo del PECAN para el año 2015. Además habría que considerar las modificaciones de los objetivos del Plan en próximas revisiones.

8.4. La ordenación del territorio canario como factor determinante en la planificación energética

El Archipiélago Canario está formado por siete islas que, de Este a Oeste son: Lanzarote, Fuerteventura, Gran Canaria, Tenerife, La Gomera, La Palma y El Hierro, además de seis islotes: Alegranza, Graciosa, Montaña Clara, Roque del Este, Roque del Oeste y Lobos. Se encuentra el Archipiélago al Noroeste del Continente Africano, entre las latitudes 27º 37' y 29º 25' Norte (situación subtropical) y las longitudes 13º 20' y 18º 10' al Oeste de Greenwich.

Las Islas Canarias están divididas en dos provincias: la provincia de Las Palmas, que comprende las islas de Gran Canaria, Fuerteventura y Lanzarote, y la provincia de Santa Cruz de Tenerife, con Tenerife, El Hierro, Gomera y La Palma.

La superficie total del archipiélago es de 7446 Km^2. Las Islas en su conjunto se caracterizan por presentar importantes singularidades en su entorno natural, que han llevado a proteger en torno al 40% de su superficie [159]. La protección no es homogénea en todo el territorio, sino que posee distintos grados [159].

En este sentido, en la ordenación del territorio, ha de partirse del incuestionable hecho de que el territorio del archipiélago canario viene caracterizado por factores de lectura objetiva como su situación geográfica, la estructura territorial insular, la orografía o los recursos naturales que, siempre constantes, han enmarcado su historia, condicionándola de manera singular.

Por otra parte, el reconocimiento de la variable medioambiental que hoy forma parte íntima de su cultura, impide seguir pensando en el territorio como un simple soporte físico sobre el cual desarrollar una actividad meramente urbanística o de alojamiento residencial o industrial.

Otros documentos generales que vinculan a la ordenación del territorio y determinan el régimen de usos del mismo son:

- A nivel de cada isla, el Plan Insular de Ordenación (PIO)
- A nivel municipal, el Plan General de Ordenación Urbana (PGOU)
- A nivel de cada uno de los elementos protegidos, su Plan Rector de Uso y Gestión. (PRUG)

De forma más específica, existen otros instrumentos de ordenación como son los Planes Territoriales para la planificación de la ordenación de actividades concretas. Entre ellos se encuentra los Planes Territoriales Energéticos donde, para el caso particular de la energía eólica, se delimitan zonas potenciales para la implantación de este tipo de infraestructuras, atendiendo a su compatibilidad con el resto de actividades y al potencial del aprovechamiento del recurso eólico.

Con relación simplemente al potencial eólico de las diferentes zonas del archipiélago se han elaborado los mapas eólicos de canarias [160]. En la figura 8.7 se muestran los mapas eólicos de las islas de Gran Canaria y Tenerife, islas donde se concentra el 80% de la potencia eólica instalada actualmente [152]. Esa misma proporción es la que se ha planificado para los 1025 MW de potencia eólica que se pretenden tener instalados en el archipiélago en el año 2015 [156,5].

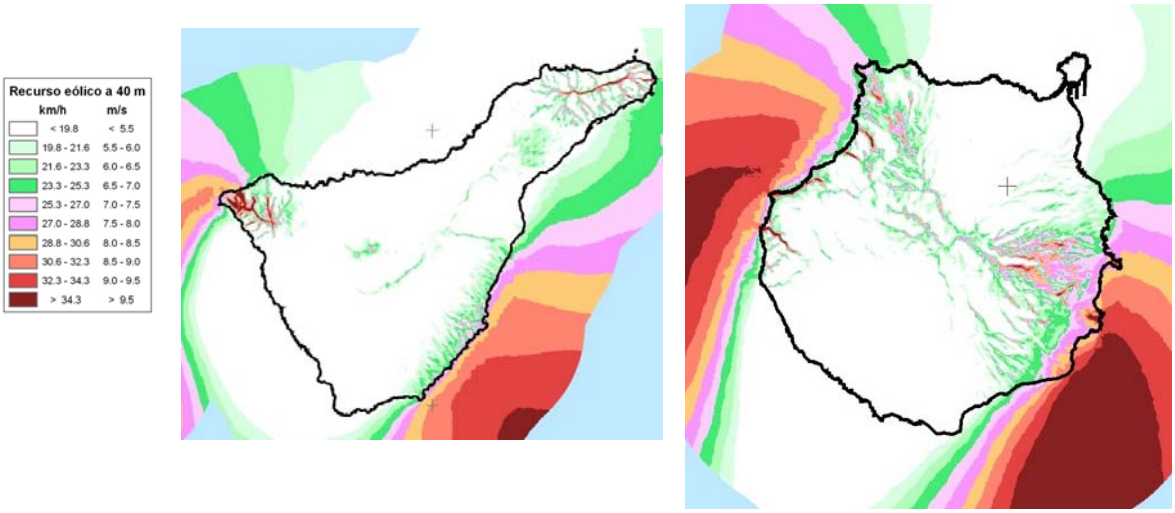

Figura 8.7: Mapas Eólicos de las islas de Gran Canaria y Tenerife

Los parques eólicos que se encuentran actualmente instalados en el archipiélago canario y más concretamente en las dos islas mencionadas anteriormente, se concentran en la zonas que se muestran en la figura 8.8 [152].

Si esta última figura se compara con la 8.7, se deduce que los parques eólicos instalados actualmente se concentran en las zonas de mayor potencial eólico.

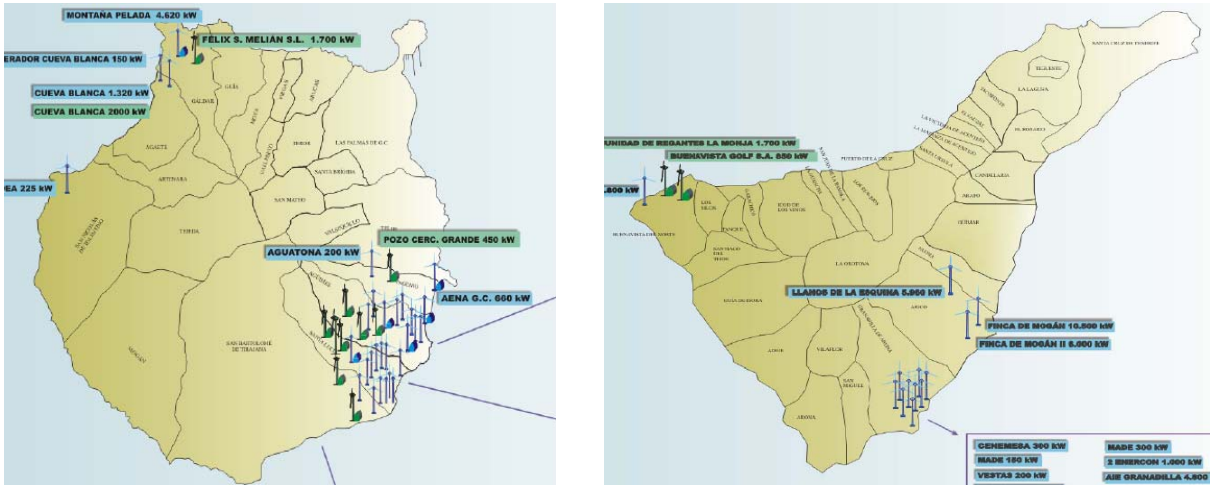

Figura 8.8: Ubicación relativa de los parques eólicos instalados en las islas de Gran Canaria y Tenerife.

Tal y como se expuso en el apartado anterior, la potencia eólica pendiente por instalar para lograr el objetivo de los 1025MW en el año 2015 era de 884MW. Esta nueva potencia irá ubicándose en zonas que generalmente tendrán menor potencial eólico que la media de las zonas ocupadas actualmente, o bien se ubicarán en zonas próximas a las anteriores, por su condición de alto potencial eólico, provocando en muchos de los casos pérdidas adicionales del rendimiento energético de las instalaciones por efecto estela [45] debido a la cada vez mayor concentración de aerogeneradores. Este hecho irá teniendo más relevancia a la hora de evaluar la rentabilidad económica de este tipo de instalaciones. Dicha rentabilidad será más sensible a pequeñas variaciones del potencial eólico calculado, ya que las instalaciones tenderán a ubicarse en zonas que, por su potencial eólico, se pudieren encontrar en el umbral de la rentabilidad económica. Este hecho también es fundamental desde la perspectiva de la ordenación del territorio. En este caso habrá que afinar más en los análisis del recurso eólico de las zonas, a la hora de delimitar área de interés para la explotación de la energía eólica.

El Decreto 32/2006 [5] define el término del Área de Sensibilidad Eólica como la superficie de afección energética de un aerogenerador, dentro de la cual no puede situarse ningún otro. Este área de sensibilidad eólica es función del diámetro del rotor de aerogenerador (el rotor está formado por las palas y el buje).

En la definición dada por [5], el Área de Sensibilidad Eólica es un rectángulo de lados 8 y 2 veces el diámetro del rotor (ϕ) y se determina mediante la Ec 8-2.

(Ec 8-2) $$ASE_{afectada} = 8\phi \times 2\phi = 16\phi^2$$

En la tabla 8.1 se expone la estimación del área de sensibilidad eólica, en Km^2, que estará afectada por la potencia eólica prevista a instalar en las islas de Gran Canaria y Tenerife. Como se vio anteriormente estas abarcarán el 80% de la potencia eólica total instalada en el archipiélago en el horizonte del 2015.

Como superficie “protegida” se ha considerado aquella que se encuentra afectada por algunos de los elementos de protección descritos en el Decreto Legislativo 1/2000 [159]. La superficie “No Protegida” será la diferencia entre la total de la isla y la anterior. La potencia eólica en 2015 es la que se considera en el Decreto 32/2006 para estas islas [5]. Para el cálculo del área de sensibilidad eólica afectada por esta potencia se ha considerado que la misma es cubierta por aerogeneradores con potencia unitaria equivalente de 2MW y con un diámetro de rotor de 80metros. Con ello se ha determina el número de aerogeneradores equivalentes y mediante la Ec 8-1, el Área de Sensibilidad Eólica afectada.

Esta área equivale según los datos de la Tabla 8.1 a un 2,4% y 1,9% de la superficie “no protegida.

Tabla 8.1: Área de Sensibilidad Eólica afectada para las islas de Gran Canaria y Tenerife por la potencia eólica instalada en el año 2015.

ISLA	Superficie Total Isla (Km^2)	Superficie "Protegida" (Km^2)	Superficie "No Protegida" (Km^2)	Potencia Eólica en 2015 (MW)	Nº Aerogeneradores de 2MW Equivalentes	Área de Sensibilidad Eólica afectada (ASE) (km^2)	Proporción ASE sobre Superficie "No Protegida"
GRAN CANARIA	1560	42,7%	894	411	205,5	21,04	2,4%
TENERIFE	2034	48%	1058	402	201	20,58	1,9%

Hay que tener en cuenta que el porcentaje de superficie afectada será realmente superior a la calculada anteriormente. En el cálculo anterior no se ha considerado por ejemplo la superficie destinada a áreas urbanas, dentro de la cual tampoco pueden ubicarse este tipo de instalaciones, ni en zonas que disten menos de 250 metros de su perimetral [5]. Además, otros documentos de ordenación del territorio como son, los Planes Insulares de Ordenación o los Planes Generales de Ordenación de cada municipio, pudieren excluir la instalación de los parques eólicos en otro tipo de áreas distintas de las ya consideradas por [159]

8.5. Conclusiones

1. La potencia eólica instalada en Canarias tuvo un crecimiento exponencial entre los años 1990 y 2000.
2. Los parques eólicos instalados han ido ocupando los emplazamientos de mayor potencial eólico de cada una de las islas.
3. Las islas de Gran Canaria y Tenerife abarcan el 80% de la potencia eólica instalada en Canarias y que a finales de 2009 alcanzaba los 141MW.
4. Los últimos parques eólicos a los que se han asignado potencia han tenido que instalarse en zonas, que si bien podrían poseer un buen potencial eólico, sus condiciones no llegaban a igualar a la de los primeros. Por otro lado, el crecimiento de la potencia eólica instalada con el tiempo, ha ocasionado una cada vez mayor concentración de aerogeneradores en las áreas potencialmente productivas, con la consecuente afección energética entre ellos [45]. Entre otros, estos dos motivos han ocasionado una disminución del rendimiento energético medio de los parques eólicos

instalados en Canarias, pasando de las 3057 horas equivalentes medias en el año 2001 a las 2640 horas equivalentes medias en el 2009.

5. La potencia eólica que se pretende tener instalada en Canarias con el horizonte de 2015 es de 1025MW [156]. Comparándola con la instalada a finales de 2009, quedaría por instalar 884MW. Esta potencia eólica se instalará generalmente en zonas de menor potencial eólico en relación a aquellas donde se encuentran los parques eólicos actuales. Por otro lado, aumentará la concentración de aerogeneradores instalados en áreas concretas (aumento de la potencia eólica por unidad de superficie). Todo ello provocará un descenso aún mayor del rendimiento energético medio de la potencia eólica que se instale en Canarias. Este hecho aumentará en gran medida la sensibilidad de la rentabilidad económica de los nuevos proyectos de parques eólicos al ir ubicándose en zonas que se encuentran en el umbral de la rentabilidad. Además hay que considerar dicha sensibilidad a la hora de delimitar las zonas estratégicas para la implantación de este tipo de infraestructuras, en los potenciales documentos de ordenación que se desarrollen.
6. Por todo lo expuesto anteriormente se concluye que es fundamental, en el desarrollo de los proyectos de parques eólicos, el conocer perfectamente el recurso eólico de las áreas donde se implantarán la nuevas instalaciones eólicas dentro del archipiélago canario
7. Según Hiester and Pennell [6], es difícil de estimar con cierta precisión los valores medios del comportamiento del viento con menos de 10 años de datos en el sitio candidato. Esta opción supone incrementar el costo involucrado en la campaña de medida y, fundamentalmente, posponer durante un tiempo, normalmente no aceptable, la toma de decisiones. Es por ello que se hace necesario el desarrollar modelos mediante los cuales se estime el recurso eólico a largo plazo de un emplazamiento candidato (lugar donde se ubicará la instalación eólica) a partir de la información eólica que se pudiere disponer de otros emplazamientos de referencia.

CAPITULO 9

Influencia de las señales de la capa de entrada de las Redes Neuronales en la estimación de la potencia eólica de un sitio candidato

INDICE

9 INFLUENCIA DE LAS SEÑALES DE LA CAPA DE ENTRADA DE LAS REDES NEURONALES EN LA ESTIMACIÓN DE LA POTENCIA EÓLICA DE UN SITIO CANDIDATO 193
9.1 Introducción 193
9.2 Arquitectura de las Redes Neuronales utilizadas. 196
9.3 Datos utilizados en el estudio 197
9.4 Metodología 201
9.5 Análisis de los resultados 205
9.5.1 Conclusiones al capítulo 216

9 INFLUENCIA DE LAS SEÑALES DE LA CAPA DE ENTRADA DE LAS REDES NEURONALES EN LA ESTIMACIÓN DE LA POTENCIA EÓLICA DE UN SITIO CANDIDATO

9.1 *Introducción*

En la literatura científica relacionada con las energías renovables se han divulgado diversos métodos para estimar la velocidad media del viento, en un periodo dado de tiempo, de un sitio candidato o sitio objetivo en el que se dispone de una serie incompleta de registro de datos de viento. Algunos autores han usado dichos métodos para estimar valores perdidos en una serie anual de velocidades de viento registrada en un determinado lugar [162]. Sin embargo, fundamentalmente, estos métodos han sido propuestos para estimar las velocidades del viento a largo plazo (diez años o más) [18,163,87,16] en un sitio candidato para el aprovechamiento de la energía eólica en el que solo se dispone de datos durante un periodo corto (normalmente un año). La estimación de la velocidad del viento a largo plazo se justifica por la variabilidad interanual del mismo. Esta variabilidad influye en la energía generada por un aerogenerador, la cual es muy sensible a la velocidad de viento que actúa sobre la misma durante su vida útil. El conocimiento del comportamiento del viento durante un único año no es suficiente para estimar su comportamiento medio [6]. Por ello, para llevar a cabo la evaluación de la viabilidad económica de la inversión que se pretenda realizar en la instalación de un sistema de conversión de energía eólica se precisa estimar el comportamiento medio del viento a largo plazo.

Para cubrir los objetivos señalados, los mencionados métodos requieren del empleo de datos de viento registrados, a largo plazo, en estaciones anemométricas de referencia cercanas. En la Fig 9.1 se muestra un esquema del procedimiento normalmente empleado. Utilizando las series de datos de viento registradas en las estaciones de referencia y candidata en el corto periodo común de disposición de datos se selecciona la arquitectura del modelo, se entrena, valida y ensaya [164] (véase esta fase señalada con el número 1 encerrado en un circulo en la Fig 9.1.). Posteriormente, se alimenta al modelo con las series de datos conocidos a largo plazo de las estaciones de referencia (véase esta etapa señala con el número 2 encerrado en un circulo en la Fig 9.1) y se estiman las velocidades y direcciones desconocidas a largo plazo en la estación objetivo o estación candidata (esta fase se señalada con el número 3 encerrado en un circulo en la Fig 9.1). Cuanto mejores sean los métodos de estimación que se diseñen en la fase 1, se prevé que más ajustadas serán las estimaciones que se realicen a largo plazo [9].

Entre los diversos métodos utilizados se pueden señalar los tradicionales algoritmos MCP (Measure-Correlate-Predict) [16,9,10,14] y los métodos que recurren a técnicas de aprendizaje automático [21-28]. Los primeros suelen utilizar una sola estación de referencia en la estimación de los datos desconocidos de la estación objetivo. Con algunas excepciones [16,10], la mayoría de los tradicionales métodos MCP usan algoritmos de regresión lineal [77] para caracterizar la relación entre las velocidades del viento del sitio candidato y del sitio de referencia. Generalmente, los MCP agrupan las velocidades del viento horarias en función de la dirección en el sitio de referencia. Para ello, los datos son divididos en un determinado número de sectores de dirección, que normalmente son ocho de 45º o doce de 30º. Entonces, se estiman los parámetros que definen las rectas de regresión del modelo, para cada sector de dirección [9]. Es decir, los parámetros de los modelos son función de la velocidad y la dirección del viento.

Los segundos son algoritmos inspirados en la Biología, como son las redes neuronales artificiales (ANNs) (Artificial Neural Networks) [21-27], y algoritmos estadísticos de aprendizaje estadístico, como son las Redes Bayesianas (Bayesian Networks) (BNs) [28]. Las técnicas de aprendizaje automático permiten la utilización de información disponible de varias estaciones de referencia y en la mayoría de los trabajos que se han publicado se ha usado dicha potencialidad. Por tanto, estos modelos inteligentes suelen involucrar información regional del recurso eólico a la hora de estimar los datos de viento de una estación objetivo.

Con alguna excepción [25], en el aprendizaje supervisado de la red los modelos de ANNs utilizados en la literatura científica usan como señales de la capa de entrada variables meteorológicas registradas en estaciones de referencia seleccionadas. Un alto porcentaje de dichos modelos solamente usan como señales de la capa de entrada las velocidades de viento registradas en estaciones de referencia seleccionadas. Las topologías de ANNs utilizadas cuentan con una sola neurona en la capa de salida, siendo la señal de salida la velocidad del viento estimada en el lugar candidato. Es decir, la mayoría de los modelos utilizados ignoran la influencia que puede tener la dirección del viento de las estaciones de referencia en la estimación de las velocidades del viento de la estación objetivo [21-25]. En [170] se estudia la influencia de la dirección del viento, en magnitud angular, en la estimación de la velocidad del viento en terrenos complejos. Sin embargo, de las cinco estaciones anemométricas utilizadas en dicho estudio siempre se utiliza la misma estación objetivo y los coeficientes de correlación entre estaciones son del mismo orden.

En este capítulo se analiza la influencia que el número de estaciones de referencia, el grado de correlación entre las velocidades de viento de las estaciones de referencia y la estación

candidata, la dirección del viento y la forma en que la señal de dirección es introducida en la capa de entrada, tienen en la estimación de la potencia generada por una turbina eólica instalada en el lugar candidato. Dicho análisis se centra en la fase 1 señalada en la Fig 9.1. Es decir, en la etapa de entrenamiento, validación y ensayo de los modelos. Las conclusiones que se obtengan del análisis realizado en esta etapa podrán permitir establecer recomendaciones a la hora de utilizar las ANNs en la estimación de las velocidades del viento y energía generada por una turbina eólica a largo plazo.

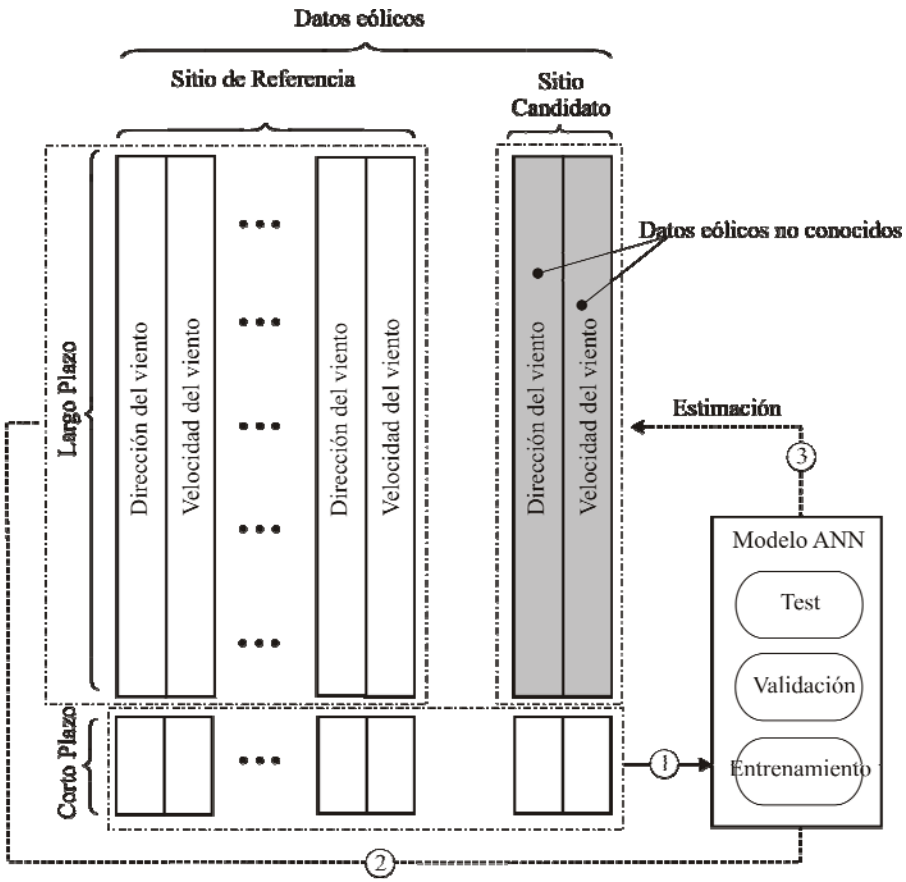

Figura 9.1: Fases del procesos de estimación de las velocidades de viento a largo plazo

Para la realización del estudio se han utilizado velocidades y direcciones medias horarias de viento registradas en veintidós estaciones anemométricas instaladas en seis de las siete islas que componen el Archipiélago Canario, España. Asimismo, se han utilizado las curvas características potencia-velocidad del viento de cinco turbinas eólicas de diferentes potencias nominales [165,166].

9.2 *Arquitectura de las Redes Neuronales utilizadas.*

Las ANNs utilizadas en este capítulo han consistido en redes de tres capas con conexiones hacia delante (feedforward). Más concretamente, se han usado topologías multilayer perceptrons (MLPs) [167-168]. Con el objeto de no incrementar el tiempo de entrenamiento se ha usado una única capa de neuronas ocultas. Dicha arquitectura ha demostrado su capacidad de aproximar satisfactoriamente cualquier transformación continua [167-168] y ha sido propuesta por diversos autores [21,24,26]. Para la elección del número de neuronas ocultas se llevaron a cabo varias pruebas previas, variando el número de señales de entrada. Dichas pruebas reflejaron que el uso de un número de neuronas superior a veinte incrementaba el tiempo de entrenamiento y no proporcionaba una mejora de los resultados. Por tanto, se fijó en veinte el número de neuronas de la capa oculta. El número de neuronas de la capa de entrada varía en función de las hipótesis analizadas. Es decir, depende del número de estaciones de referencia empleadas y de la consideración o no de la señal de dirección de la velocidad del viento. En la mayoría de las hipótesis consideradas la capa de salida tiene una sola neurona. La señal de salida proporcionada por dicha neurona es la velocidad media horaria estimada del viento en la estación objetivo. En la hipótesis donde las señales de entrada a la ANN, para cada estación de referencia, son las componentes según un sistema de ejes cartesianos de la velocidad del viento, la capa de salida de la red contiene dos neuronas. Las salidas proporcionadas por dichas neuronas son las componentes, según cada uno de los ejes del sistema de referencia cartesiano indicado, de la velocidad media horaria estimada del viento en la estación objetivo.

Las arquitecturas diseñadas han sido entrenadas usando el algoritmo de Backpropagation con función de activación sigmoidal [167-168].

Como algoritmo de minimización del error cuadrático medio cometido en el aprendizaje se ha utilizado el de Levemberg-Marquard [77,167].

Para llevar a cabo el entrenamiento y ensayo de la red la serie anual de datos disponibles para las estaciones de referencia y objetivo, se han dividido en tres subconjuntos aleatorios y diferentes: los datos de entrenamiento, los datos de validación y los datos de ensayo [164]. La proporción de datos seleccionada para cada una de los procesos ha sido de 60%,20% y 20%, respectivamente.

El subconjunto de datos de entrenamiento se utiliza para la estimación de los pesos de la ANNs. El subconjunto de validación es utilizado para chequear el progreso del entrenamiento de las ANNs, optimizando los parámetros de las mismas. Es decir, se utilizan para medir el

grado de generalización de las ANNs. El subconjunto de los datos de ensayo, que no han sido utilizados ni en la etapa de entrenamiento ni de validación, es usado para calcular el porcentaje de error de la red final optimizada. Es decir, constituye una medida independiente del funcionamiento de la red después del entrenamiento.

Los distintos experimentos han sido realizados empleando el algoritmo trainlm disponible en la Toolbox de redes neuronales de MATLAB [169].

9.3 *Datos utilizados en el estudio*

Los datos meteorológicos utilizados en este capítulo (velocidades y direcciones medias horarias del viento) han sido registrados en veintidós estaciones meteorológicas instaladas en seis de las siete islas que componen el archipiélago canario, España (Fig 9.2). Puede observarse que todos los dispositivos de registro están situados en las costas de las islas, con excepción de la estación WS-13, que está situada en el centro de la isla de Gran Canaria. Las series de datos utilizados nos han sido cedidas por la Agencia Estatal de Meteorología (AEMET) del Ministerio de Medio Ambiente, y Medio Rural y Marino del Gobierno de España y por el Instituto Tecnológico de Canarias (ITC).

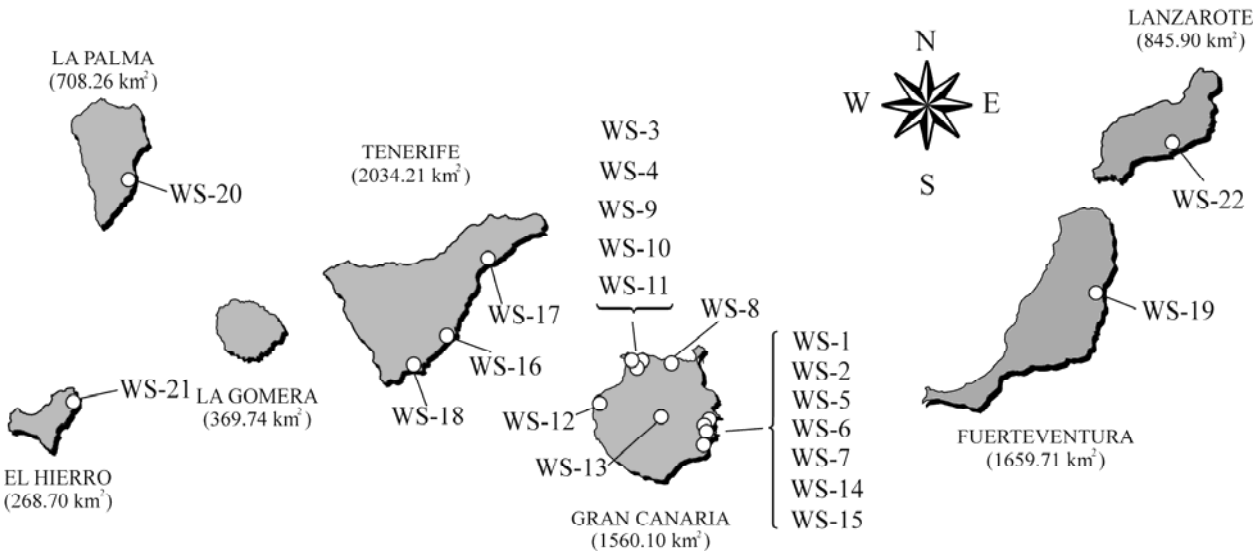

Figura 9.2: Ubicación de las estaciones anemométricas utilizadas.

En la primera columna de la Tabla 1 se muestran los códigos asignados a cada estación meteorológica. Asimismo, se indica en la Tabla 1 el periodo de medida, la fuente de

procedencia de los datos, la altura sobre el nivel del suelo de los dispositivos de medida, las coordenadas geográficas de las estaciones (latitud, longitud y altitud), la media anual y la desviación estándar de la velocidad viento.

Tabla 9.1: Estaciones meteorológicas utilizadas en el estudio.

Estación Meteorológica	Año	Fuente	Altura (m)	Coordenadas Geográficas			Velocidad media anual (m/s)	Desviación estándar (m/s)
				Latitud Norte	Longitud Este	Altitud (m)		
WS-1	2002	AEMET	10	27º55'44"	15º23'20"	16	7.35	3.71
WS-1	2006	AEMET	10	27º55'44"	15º23'20"	16	7.09	3.49
WS-2	2002	ITC	10	27º56'46"	15º23'06"	9	6.11	3.06
WS-3	2002	ITC	10	28º07'30"	15º40'37"	472	7.51	3.88
WS-4	2002	ITC	20	28º07'30"	15º40'37"	472	7.67	3.85
WS-5	2006	ITC	10	27º51'36"	15º23'13"	3	6.88	3.64
WS-6	2006	ITC	10	27º51'07"	15º24'29"	7	6.02	3.59
WS-7	2006	ITC	20	27º51'07"	15º24'29	7	6.95	3.62
WS-8	2006	ITC	13	28º09'14"	15º31'44"	15	3.53	2.32
WS-9	2006	ITC	15	28º09'47"	15º42'25"	57	8.21	3.97
WS-10	2006	ITC	20	28º10'12"	15º38'20"	30	5.86	3.18
WS-11	2006	ITC	10	28º10'12"	15º38'20"	30	5.60	3.09
WS-12	2006	ITC	15	28º00'00"	15º48'47"	6	5.15	2.94
WS-13	2006	ITC	20	27º57'36"	15º33'36"	1905	6.61	4.37
WS-14	2006	ITC	25	27º51'47"	15º25'12"	37	6.08	3.39
WS-15	2002	ITC	10	27º53'24"	15º23'42"	3	6.36	3.38
WS-16	2006	ITC	10	28º06'36"	16º29'06"	79	5.35	3.66
WS-17	2002	ITC	10	28º25'12"	16º21'18"	732	6.26	5.26
WS-18	2002	AEMET	10	28º02'35"	16º34'16"	51	5.53	3.26
WS-18	2006	AEMET	10	28º02'35"	16º34'16"	51	5.17	2.91
WS-19	2002	AEMET	10	28º27'10"	13º51'54"	24	5.88	2.66
WS-19	2006	AEMET	10	28º27'10"	13º51'54"	24	5.78	2.51
WS-20	2002	AEMET	10	28º36'47"	17º45'36"	85	4.82	2.30
WS-20	2006	AEMET	10	28º36'47"	17º45'36"	85	4.45	2.23
WS-21	2002	AEMET	10	27º48'50"	17º53'10"	30	5.84	3.16
WS-22	2002	AEMET	10	28º57'07"	13º36'00"	10	5.99	3.14
WS-22	2006	AEMET	10	28º57'07"	13º36'00"	10	5.55	2.83

En las Tablas 2 y 3 se muestran los coeficientes de correlación lineal entre las velocidades medias horarias del viento de las diversas estaciones en el año 2002 y 2006, respectivamente. A pesar de las relativamente cortas distancias que existen entre los puntos de ubicación de las estaciones anemométricas, debido a la orografía de las zonas donde estas estaciones están, el rango de coeficientes de correlación oscila entre 0.04 y 1. El valor más bajo ha sido obtenido entre las estaciones WS-13 y WS-6 ubicadas en la isla de Gran Canaria (Fig 9.2). La primera situada en el centro de la isla a una altura sobre el nivel del mar de 1905 m. La segunda situada en la costa este de la misma a una altura sobre el nivel del mar de 7 m. Los coeficientes de correlación más altos se han observado entre los datos medidos en los dispositivos de registro de las estaciones (WS-3 y WS-4), (WS-6 y WS-7) y (WS-10 y WS-11). Cada una de las parejas de dichos dispositivos está ubicada en un mismo mástil, pero a distinta altura sobre el nivel del suelo.

Tabla 9.2: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2002

	WS-1	WS-2	WS-3	WS-4	WS-15	WS-17	WS-18	WS-19	WS-20	WS-21	WS-22
WS-1	1.000	0.939	0.712	0.705	0.952	0.417	0.506	0.690	0.601	0.492	0.641
WS-2	0.939	1.000	0.676	0.670	0.913	0.467	0.460	0.706	0.630	0.504	0.632
WS-3	0.712	0.676	1.000	0.999	0.741	0.241	0.604	0.588	0.506	0.421	0.564
WS-4	0.705	0.670	0.999	1.000	0.735	0.246	0.601	0.587	0.506	0.423	0.563
WS-15	0.952	0.913	0.741	0.735	1.000	0.412	0.546	0.696	0.608	0.493	0.650
WS-17	0.417	0.467	0.241	0.246	0.412	1.000	0.167	0.464	0.506	0.415	0.404
WS-18	0.506	0.460	0.604	0.601	0.546	0.167	1.000	0.512	0.393	0.300	0.511
WS-19	0.690	0.706	0.588	0.587	0.696	0.464	0.512	1.000	0.562	0.481	0.679
WS-20	0.601	0.630	0.506	0.506	0.608	0.506	0.393	0.562	1.000	0.476	0.496
WS-21	0.492	0.504	0.421	0.423	0.493	0.415	0.300	0.481	0.476	1.000	0.506
WS-22	0.641	0.632	0.564	0.563	0.650	0.404	0.511	0.679	0.496	0.506	1.000

Tabla 9.3: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2006

	WS 1	WS 5	WS 6	WS 7	WS 8	WS 9	WS 10	WS 11	WS 12	WS 13	WS 14	WS 16	WS 18	WS 19	WS 20	WS 22
WS-1	1,000	0,903	0,892	0,887	0,200	0,625	0,414	0,407	0,728	0,091	0,885	0,662	0,459	0,647	0,575	0,687
WS-5	0,903	1,000	0,902	0,896	0,197	0,712	0,518	0,504	0,717	0,109	0,902	0,671	0,450	0,633	0,559	0,662
WS-6	0,892	0,902	1,000	0,995	0,145	0,687	0,479	0,470	0,695	0,040	0,963	0,710	0,515	0,614	0,528	0,668
WS-7	0,887	0,896	0,995	1,000	0,146	0,691	0,482	0,475	0,692	0,053	0,962	0,712	0,521	0,615	0,544	0,672
WS-8	0,200	0,197	0,145	0,146	1,000	0,350	0,514	0,521	0,161	0,306	0,159	0,281	0,275	0,430	0,369	0,265
WS-9	0,625	0,712	0,687	0,691	0,350	1,000	0,809	0,802	0,528	0,272	0,688	0,699	0,546	0,553	0,510	0,515
WS-10	0,414	0,518	0,479	0,482	0,514	0,809	1,000	0,996	0,346	0,225	0,493	0,643	0,559	0,498	0,414	0,402
WS-11	0,407	0,504	0,470	0,475	0,521	0,802	0,996	1,000	0,346	0,226	0,485	0,639	0,562	0,497	0,413	0,400
WS-12	0,728	0,717	0,695	0,692	0,161	0,528	0,346	0,346	1,000	0,151	0,701	0,523	0,353	0,510	0,479	0,570
WS-13	0,091	0,109	0,040	0,053	0,306	0,272	0,225	0,226	0,151	1,000	0,069	0,145	0,059	0,215	0,301	0,131
WS-14	0,885	0,902	0,963	0,962	0,159	0,688	0,493	0,485	0,701	0,069	1,000	0,721	0,523	0,624	0,560	0,667
WS-16	0,662	0,671	0,710	0,712	0,281	0,699	0,643	0,639	0,523	0,145	0,721	1,000	0,780	0,590	0,503	0,579
WS-18	0,459	0,450	0,515	0,521	0,275	0,546	0,559	0,562	0,353	0,059	0,523	0,780	1,000	0,481	0,372	0,455
WS-19	0,647	0,633	0,614	0,615	0,430	0,553	0,498	0,497	0,510	0,215	0,624	0,590	0,481	1,000	0,504	0,651
WS-20	0,575	0,559	0,528	0,544	0,369	0,510	0,414	0,413	0,479	0,301	0,560	0,503	0,372	0,504	1,000	0,503
WS-22	0,687	0,662	0,668	0,672	0,265	0,515	0,402	0,400	0,570	0,131	0,667	0,579	0,455	0,651	0,503	1,000

El régimen de vientos predominante en el Archipiélago Canario es el viento alisio, el cual sopla durante un alto porcentaje del tiempo en dirección Noreste. Fig 9.3-a muestra, a título de ejemplo representativo de la dirección predominante del viento en Canarias, la rosa de los vientos de la WS-5. Sin embargo, existen algunas estaciones que, afectadas por las condiciones orográficas, presentan rosas de los vientos con otras direcciones predominantes. Fig 9. 3-b muestra la rosa de los vientos de la WS-12 como ejemplo representativo de estas estaciones.

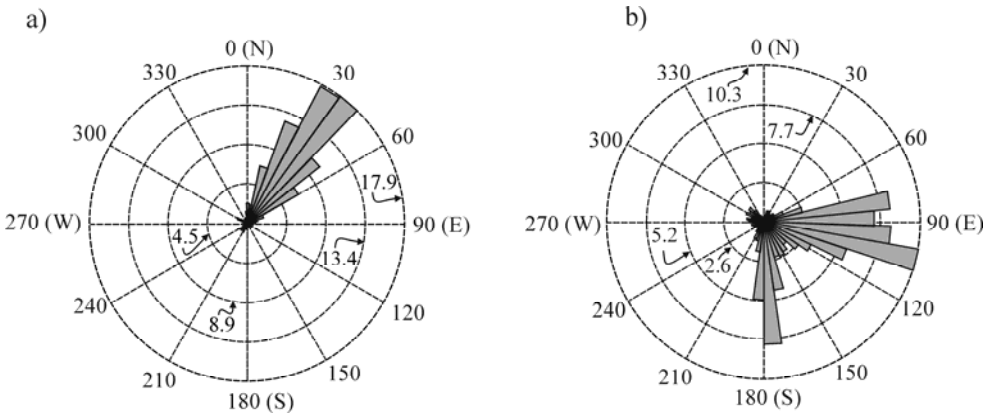

Figura 9.3: Rosas de los vientos de estaciones anemométricas en el año 2006: a) WS-5, b) WS-12.

Los modelos de turbinas eólicas utilizados en este estudio [165-166] se han escogido de tal forma que se correspondan con diferentes rangos de potencia nominal. Las curvas características potencia velocidad de dichas turbinas se muestran en la Fig 9.4.

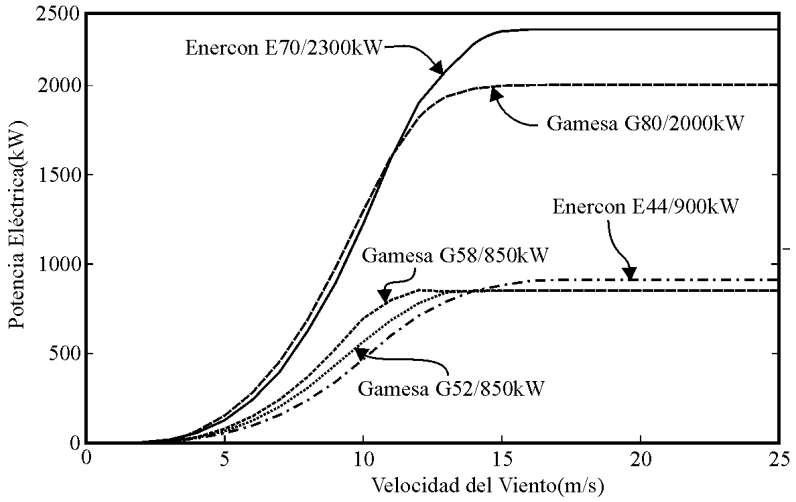

Figura 9.4: Curvas características potencia-velocidad del viento de los aerogeneradores utilizados en el estudio.

9.4 Metodología

Con la metodología aquí propuesta se pretende analizar la influencia que el número de estaciones de referencia utilizadas, la correlación existente entre las velocidades de vientos de dichas estaciones de referencia, la dirección del viento y la forma en que la señal de dirección alimenta a la capa de entrada de las redes neuronales tienen en la estimación de tres variables de la estación candidata. Dichas variables son: a) las velocidades medias horarias del viento, b) las densidades de potencias medias horarias del viento y c) las potencias eléctricas horarias generadas por turbinas eólicas que se instalasen en el lugar candidato.

La medida de las distintas influencias se lleva cabo mediante el análisis de los errores obtenidos en las evaluaciones realizadas con el conjunto de datos que no han sido empleados en el entrenamiento de las redes. Dichos errores se han evaluado con dos métricas. Estas métricas han sido el error absoluto relativo medio (mean absolute relative error) (MARE) (Ec 9-1), y el coeficiente de correlación (CC), Ec 9-2, las cuales han sido también utilizadas por otros autores [6,14].

(Ec 9-1) $$MARE = \frac{1}{n}\sum_{i=1}^{n}\frac{|T_i - O_i|}{T_i}$$

(Ec 9-2) $$CC = \frac{\sum_{i=1}^{n}\left(T_i - \overline{T}\right)\left(O_i - \overline{O}\right)}{\sqrt{\left[\sum_{i=1}^{n}(T_i - \overline{T})^2\right]\left[\sum_{i=1}^{n}(O_i - \overline{O})^2\right]}}$$

Donde n es el número de datos del conjunto de ensayo; O_i son los datos estimados con el modelo; $\overline{O}$ es la media de los valores O_i ; T_i son los datos medidos o reales y $\overline{T}$ es la media de los valores T_i.

El proceso metodológico seguido ha sido el siguiente:

A) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con una sola entrada y una sola salida. Es decir en la Fig 9.5, N=1. La señal de entrada es la serie de velocidades del viento de una estación de referencia y la señal de salida la serie de velocidades del viento de la estación objetivo.

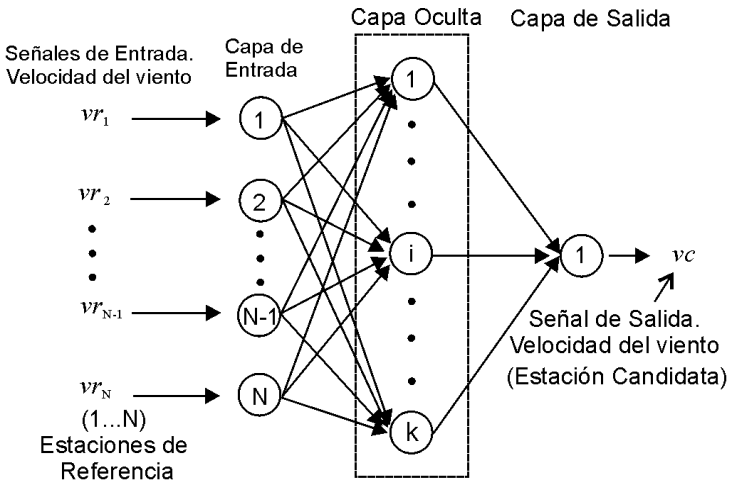

Figura 9.5: Esquema de una ANN con N señales de entrada de velocidad del viento de estaciones de referencia y una señal de salida de velocidad del viento de la estación candidata.

En este apartado todas las estaciones podrán actuar como de estación de referencia y como estación objetivo. Teniendo en cuenta el número de estaciones disponibles (Tabla 1), el

número de combinaciones posibles es de 55 en el año 2002 y 120 en el año 2006. Por tanto, el número de casos analizados ha sido de 175.

B) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con dos señales de entrada y una sola salida. Es decir en la Fig 9.6, N=1. Las señales de entrada son las series de velocidades y direcciones del viento de una estación de referencia y la señal de salida la serie de velocidades del viento de la estación objetivo. En estos modelos la señal de dirección del viento es introducida en magnitud angular (0º-360º) y el norte es el que se considera como ángulo 0º. Al igual que en el caso anterior, todas las estaciones podrán actuar como de estación de referencia y como estación objetivo. Por tanto, el número de casos analizados es aquí también de 175.

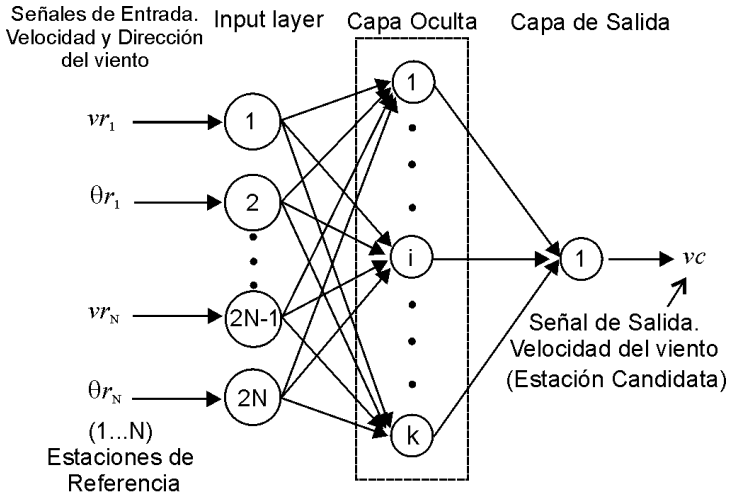

Figura 9.6: Esquema de una ANN con 2N señales de entrada de velocidad y dirección angular del viento del viento de N estaciones de referencia y una señal de salida de velocidad del viento de la estación candidata.

C) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con dos señales entrada y dos señales de salida. Es decir, en la Fig 9.7-a, N=1. Las señales de entrada son las dos series de componentes cartesianas (*vrx,vry*) de la velocidad del viento de la estación de referencia y las señales de salida las dos series de componentes cartesianas (*vcx,vcy*) de la velocidad del viento de la estación objetivo. El parámetro dirección del viento se mide, a partir del norte, en sentido de las agujas del reloj (Eje y en la Fig 9.7-b). Los módulos vc_i de la serie de velocidades de salida de los 175 casos analizados se obtienen a partir de Ec 9-3.

(Ec 9-3) $$vc_i = \sqrt{vcx_i^2 + vcy_i^2}$$

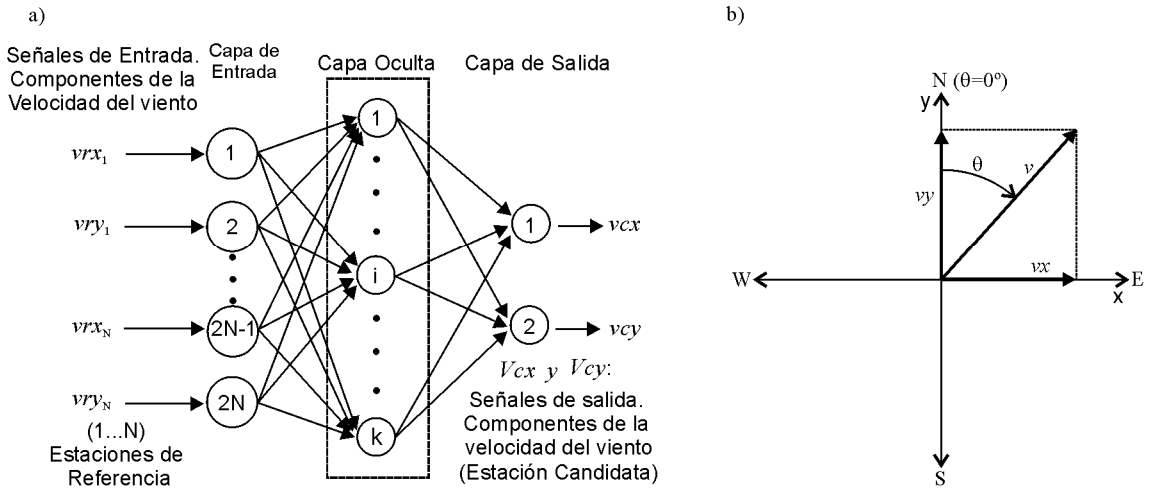

Figura 9.7: a) Esquema de una ANN con 2N señales de entrada de las componentes cartesianas de velocidad del viento de N estaciones de referencia y dos señales de salida de las componentes cartesianas de velocidad del viento de la estación candidata. b) Descomposición cartesiana de la velocidad del viento .

D) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con 2N (N>1) señales de entrada y una única señal de salida (Fig 9.6). Las 2N señales de entrada son las series de velocidades y direcciones del viento de N estaciones de referencia y la señal de salida la serie de velocidades del viento de la estación objetivo.

E) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con N (N>1) señales de entrada y una única señal de salida (Fig 9.5). Las N señales de entrada son las series de velocidades del viento de N estaciones de referencia y la señal de salida la serie de velocidades del viento de la estación objetivo.

F) Determinación de los errores cometidos cuando la arquitectura de la red neuronal utilizada cuenta con 2N señales de entrada y dos señales de salida (Fig 9.7-a). Las 2N señales de entrada son las series de componentes cartesianas de las velocidades del viento de las N (N>1) estaciones de referencia y las señales de salida las dos series de componentes cartesianas (*vcx,vcy*) de la velocidad del viento de la estación objetivo.

G) Determinación, para cada uno de los apartados anteriores, de los errores cometidos en la estimación de la densidad de potencia eólica, P_i, la cual se determina mediante la Ec 9-4 [141].

(Ec 9-4) $$P_i = \frac{1}{2}\rho_i v_i^3$$

En la ecuación 9-4, si la densidad (ρ_i) se expresa en Kg m^{-3} y la velocidad (v) en m s^{-1}, la potencia eólica obtenida (P_i) será en W m^{-2}. La densidad del aire es una variable continua que depende de la presión, temperatura y la humedad. En la literatura científica se asume que ésta es constante. El valor utilizado en toda la literatura consultada es ρ=1.225 kgm^{-3} , correspondiente a las condiciones estándares (a nivel del mar, 15ºC) [141].

H) Determinación para cada uno de los apartados anteriores de los errores cometidos en la estimación de la potencia eléctrica media generada por las cinco turbinas eólicas seleccionadas (Fig 9.4). Los fabricantes suelen suministrar las curvas de potencia de sus aerogeneradores en forma discreta con M puntos (Pwt_i, v_i). La potencia eléctrica obtenible entre dos puntos ‘‘i” y‘‘i + 1” de la curva de potencia se puede calcularse de forma aproximada [170]. Una de las posibles formas de aproximación consiste en asumir que la variación entre dos puntos de la curva de potencia es lineal (Ec 9-5).

(Ec 9-5) $$PWT(v) = \frac{Pwt_{i+1} - Pwt_i}{v_{i+1} - v_i}(v - v_i) + Pwt_i$$

Hay que señalar que las velocidades de viento utilizadas en la Ec 9-5 son las estimadas en la estación objetivo a la altura indicada en la Tabla 1. Ello, se ha realizado así con el propósito de no introducir los errores que se generan con los modelos de extrapolación de la velocidad del viento con la altura.

I) Análisis comparativo de los resultados obtenidos en los apartados anteriores.

9.5 Análisis de los resultados

En la figura 9.8 se comparan los resultados obtenidos para los casos A) y B) del apartado anterior. Dicha comparación se lleva a cabo representando en ordenadas las métricas CC estimadas con la Ec 9-2 y en abscisas los coeficientes de correlación R existentes entre las velocidades del viento medidas en las estaciones de referencia y las estaciones objetivo (Tabla 2 y Tabla 3).

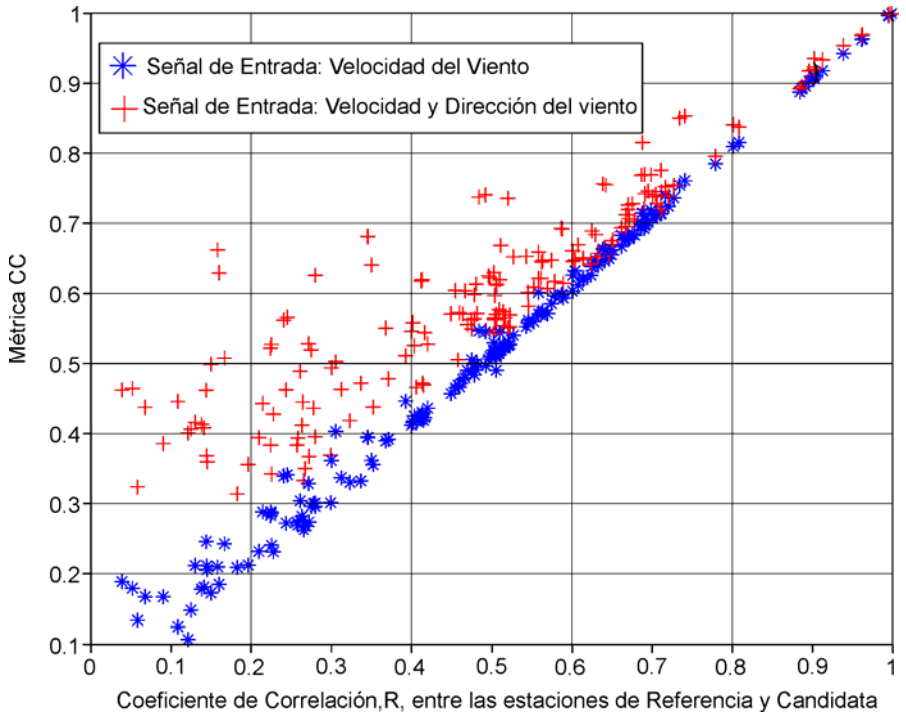

Figura 9.8: Métricas CC de los casos A) y B) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo.

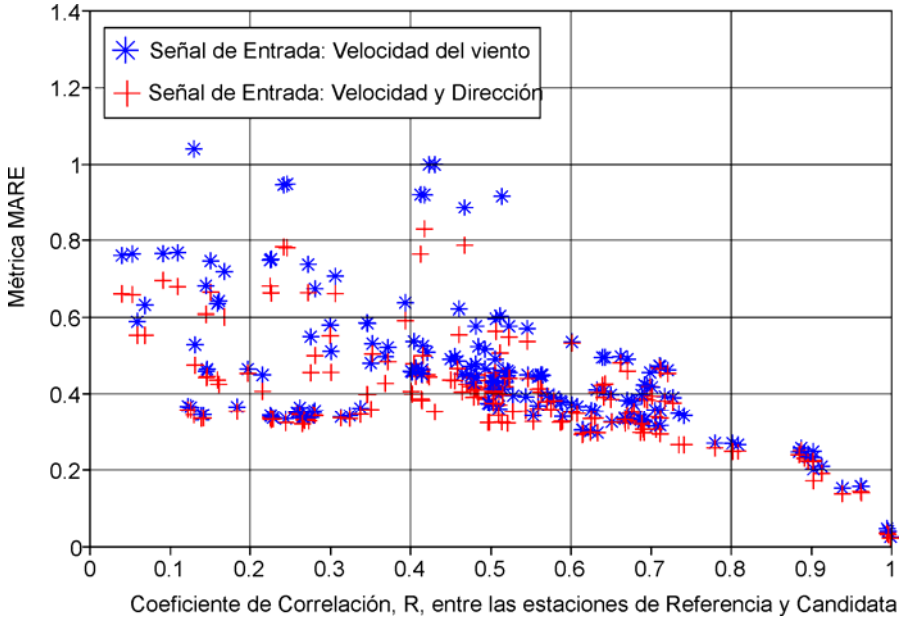

Figura 9.9: Métricas MARE de los casos A) y B) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo.

En la figura 9.9 se lleva a cabo la misma comparación, pero empleando la métrica MARE, Ec 9-1, en lugar de la métrica CC.

En ambas figuras se observa que cuando se utiliza la dirección del viento en magnitud angular como señal de entrada de las redes neuronales, las métricas obtenidas presentan en todos los casos analizados mejores resultados que los obtenidos cuando dicha señal de dirección es obviada. Sin embargo, cuando los coeficientes de correlación R son superiores a 0.98 la influencia de la señal de dirección es poco significativa. Asimismo, se desprende de las figuras 9.8 y 9.9 que la influencia favorable de la consideración de la señal de dirección es más notable cuando los coeficientes de correlación R tienen valores inferiores a 0.6. En estos casos las métricas obtenidas pueden presentar mejoras (de hasta el 100% en el caso de CC y del 20% en el caso de MARE) respecto de los resultados obtenidos obviando la señal de dirección. Además, para valores de R comprendidos entre 0.6 y 0.98 la inclusión de la dirección como señal de entrada de las redes neuronales también influye favorablemente en la estimación de las velocidades del viento de la estación objetivo.

En las figuras 9.10 y 9.11 se muestran los resultados obtenidos en la comparación de los casos B) y C) del proceso metodológico seguido. Es decir, se lleva cabo una comparación de la forma de introducir la señal de dirección en los modelos de redes neuronales. Se concluye que para valores de R superiores a 0.9 no existen diferencias significativas entre los resultados obtenidos cuando la señal de dirección se introduce explícitamente en magnitud angular o se introduce implícitamente descomponiendo la velocidad horizontal del viento en sus componentes cartesianas. Sin embargo, para valores de R comprendidos entre 0.6 y 0.9 los modelos que descomponen la velocidad en sus componentes cartesianas presentan en la mayoría de los casos peores métricas. Para valores de R inferiores a 0.6 no se observa un efecto predominante de ninguna de las dos formas de introducir la señal de dirección.

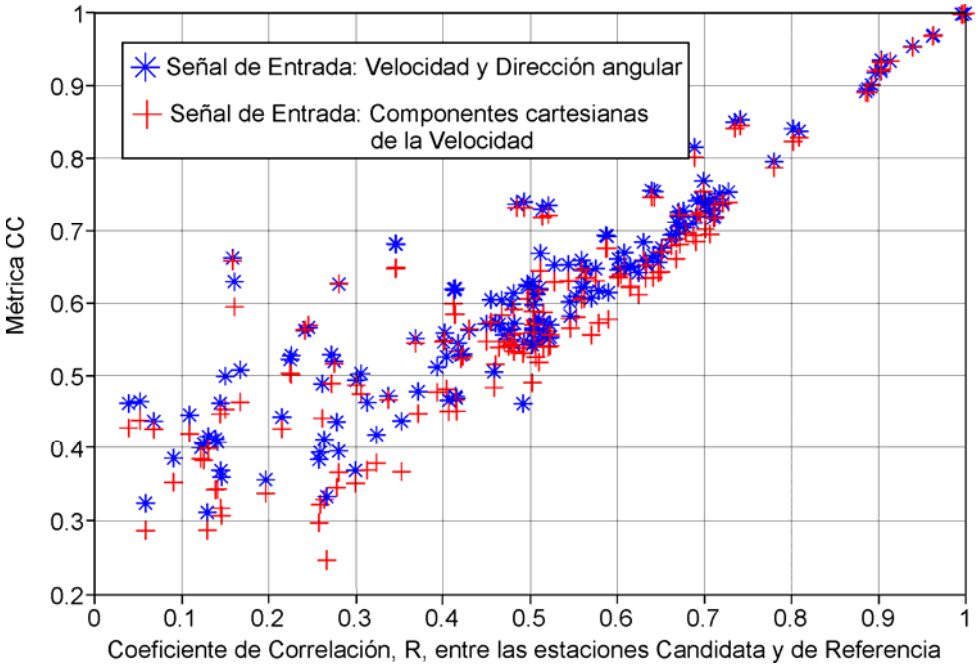

Figura 9.10: Métricas CC de los casos B) y C) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo.

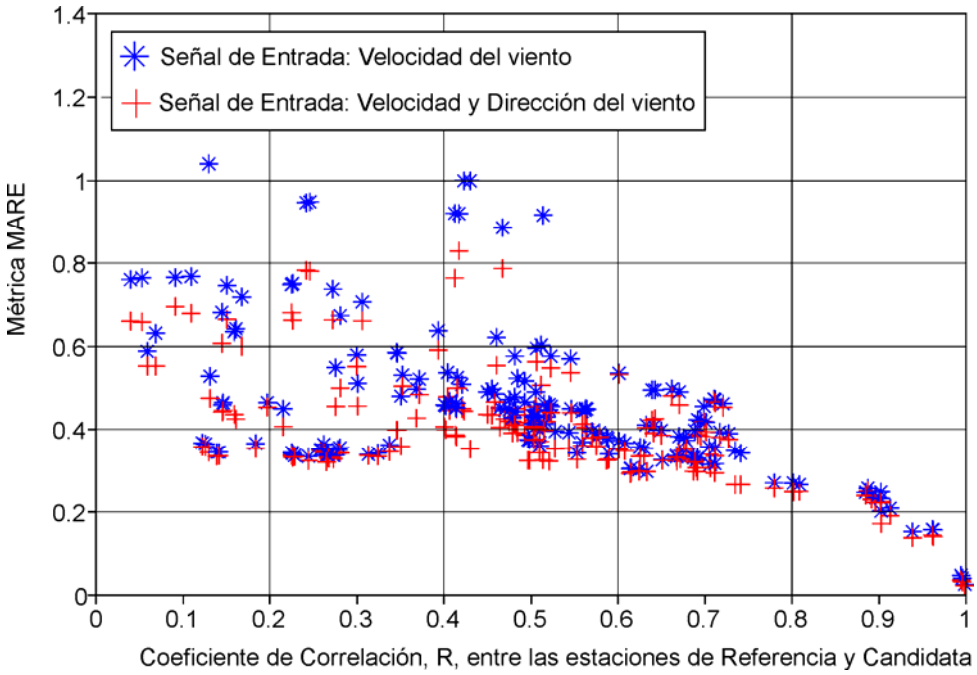

Figura 9.11: Métricas MARE de los casos B) y C) en función de los coeficientes de correlación R existentes entre las velocidades de viento de las estaciones de referencia y las estaciones objetivo.

Las figuras 9.12 y 9.13 representan, a título de ejemplo, los resultados que se han obtenidos con algunas ANNs del caso D) indicado en la metodología, cuando N=2. Es decir, se trata de ANNs con cuatro señales de entrada y una señal de salida. Se pretenden mostrar en dichas figuras los resultados alcanzados cuando a las señales de entrada de los casos B) indicados en la metodología se les añaden las señales de una segunda estación de referencia, la cual posee un R con la estación candidata que es inferior al que posee la primera. Con ello se desea analizar el efecto del R de la segunda estación de referencia en la magnitud de las métricas de error empleadas. En la figura 9.12 se muestra la métrica CC frente a R y en la figura 9.13 se muestra la métrica MARE frente a R.

Para la elaboración de las figuras 9.12 y 9.13 se ha partido de dos de los resultados representados en las figuras 9.8 y 9.9, respectivamente. Concretamente, uno de los resultados es el obtenido por la ANN cuyas señales de entrada proceden de la WS-1 y la señal de salida es la velocidad estimada de la estación WS-3. El otro resultado es el obtenido por la ANN que tiene como estación de referencia WS-2 y como estación objetivo WS-15.

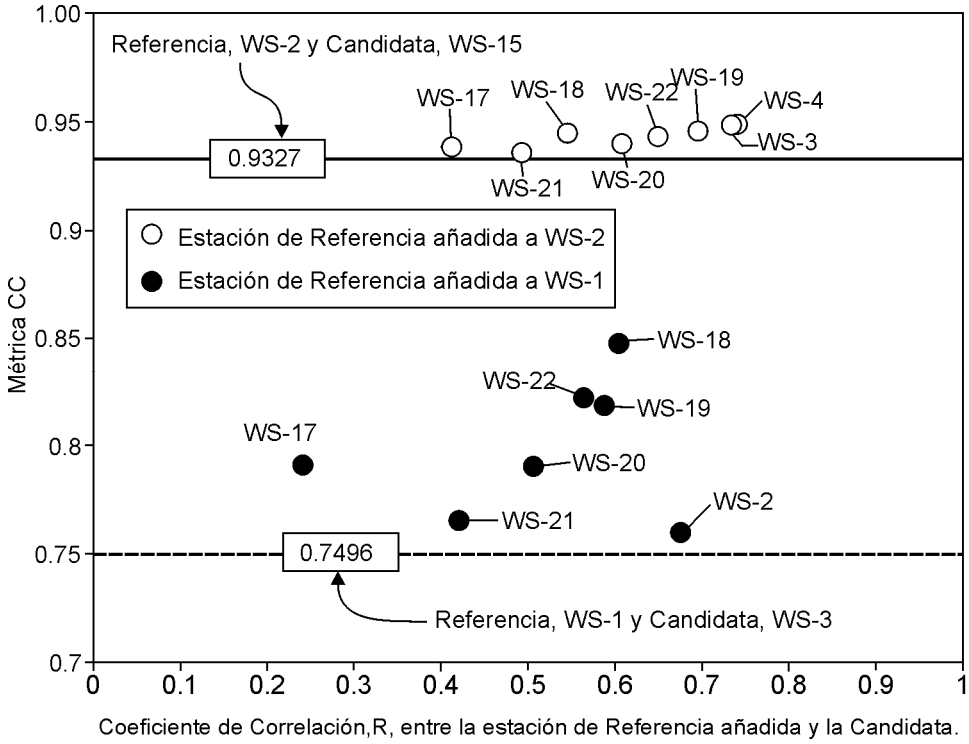

Figura 9.12: Comparación de la métrica CC de dos modelos del caso A) con la correspondiente métrica de varios modelos del caso D) con N=2. Los modelos D) se han generado añadiendo a los modelos del caso A) una segunda estación de referencia la cual posee un R con la estación candidata que es inferior al que posee la primera.

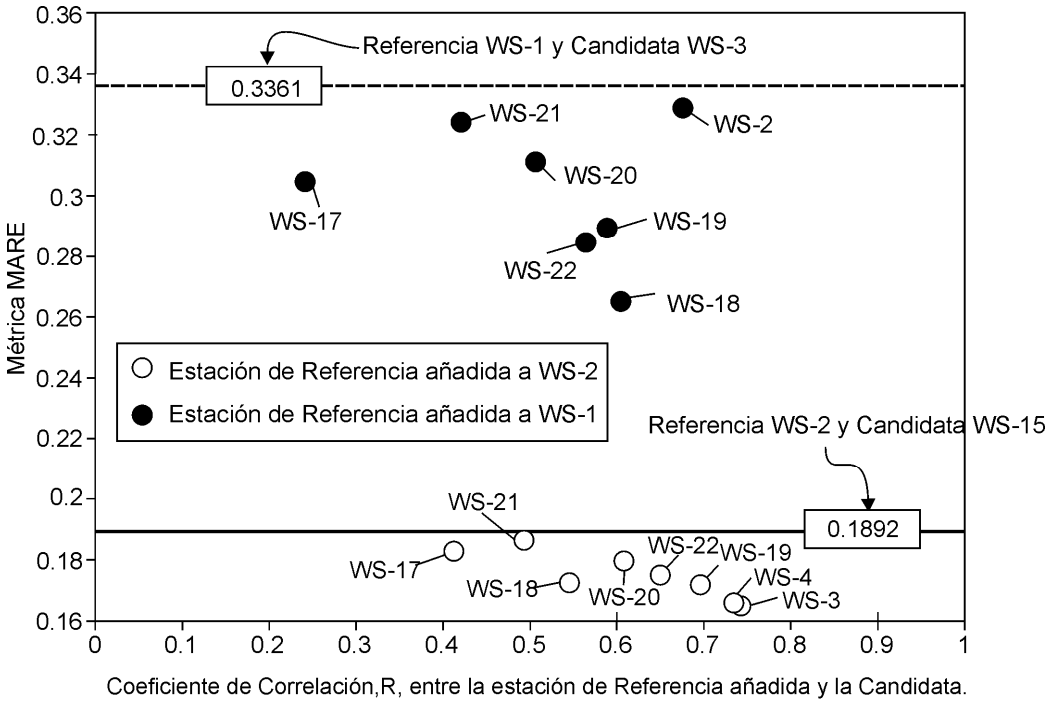

Figura 9.13: Comparación de la métrica MARE de dos modelos del caso A) con la correspondiente métrica de varios modelos del caso D) con N=2. Los modelos D) se han generado añadiendo a los modelos del caso A) una segunda estación de referencia la cual posee un R con la estación candidata que es inferior al que posee la primera.

Las estaciones WS-1 y WS-3 han presentado un R en el año 2002 de 0.712 y las métricas CC y MARE obtenidas en el caso B) han sido de 0.7496 y 0.3361, respectivamente. Dichas métricas se han representando con líneas horizontales de trazos en las figuras 9.12 y 9.13. Las estaciones WS-2 y WS-15 han presentando un R de 0.913 en el año 2002 y el CC y el MARE obtenidos en el caso B) han sido de 0.9327 y 0.1892, respectivamente. También estos valores se representan con una línea horizontal, pero continua, en las figuras 9.12 y 9.13. Partiendo de estas dos ANN se han generado las ANNs cuyas métricas se representan en las figuras 9.12 y 13, añadiendo una segunda estación de referencia con el criterio anteriormente indicado.

Puede observarse en las figuras 9.12 y 9.13 que las métricas mejoran al añadir una segunda estación de referencia, independiente de las magnitudes de los coeficientes de correlación R existentes entre la primera estación de referencia y la estación objetivo. Aunque hay que señalar que el porcentaje de mejora tiende a disminuir cuando se incrementa R, llegando a anularse la mejora cuando R alcanza el valor unidad. Puede observarse en las figuras 9.12 y

13 que con la adición de la WS-18 a la WS-1 el CC se ha incrementado un 13.02% (pasa de 0.7496 a 0.8472) y el MARE ha disminuido un 21.15% (pasa de 0.3361 a 0.265). Sin embargo, con la adición de WS-3 a WS-2 el CC se ha incrementado solo un 1.4% (pasa de 0.9327 a 0.9457) y el MARE ha disminuido un12.7% (pasa de 0.189 a 0.165). Además, se observa que el porcentaje de mejora de las métricas no muestra una dependencia con el coeficiente de correlación R que la segunda estación de referencia tiene con la estación objetivo. Los resultados que se muestran a título de ejemplo en las figuras 9.12 y 9.13 se han observado asimismo en todas las combinaciones realizadas con las restantes estaciones.

En la figura 9.14 se muestran los resultados obtenidos en el caso E) cuando se varía N. En el eje de ordenadas de la figura 9.14 se muestra el porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia y el MARE obtenido cuando se emplea una sola estación de referencia. En el eje de abscisas se representa el número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo. Para elaborar la figura 9.14 se parte de las ANNs analizadas en el caso B) a las que se les añaden estaciones de referencia que posean un R con la estación candidata inferior al que posee la primera. En dicha figura se muestran los valores medios y las desviaciones típicas de los porcentajes de variación de la métrica MARE. Asimismo, se muestran las situaciones extremas de todas las ANNs generadas. Es decir, las situaciones que han presentado una mayor y una menor variación del error.

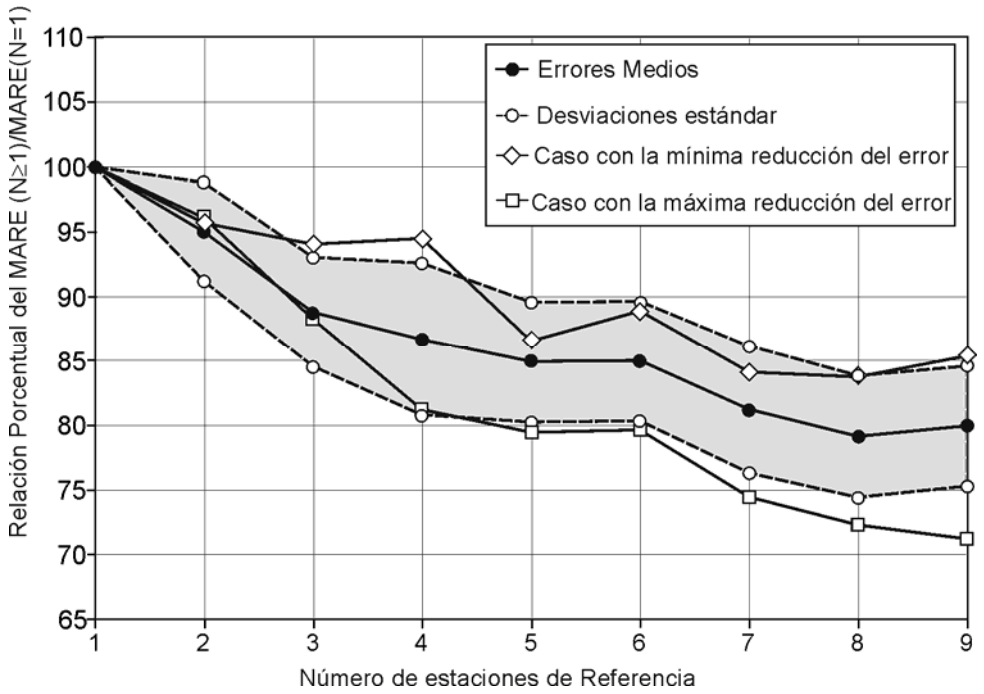

Figura 9.14: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso A), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo.

En la figura 9.14 puede observase la tendencia decreciente que presentan las variaciones de la métrica MARE al incrementarse el número de estaciones de referencia. Sin embargo, hay que señalar que no todas las estaciones de referencia añadidas mejoran los resultados. Por tanto, las curvas de tendencia pueden presentar formas de diente de sierra. También ha de resaltarse que de los ensayos realizados con todas las combinaciones posibles de estaciones se ha comprobado que la eliminación de la estaciones de referencia que incrementan el error no influye en la obtención del error mínimo. Por tanto, para detectar el mínimo error cuando se dispone de varias estaciones de referencia para estimar la velocidad de una estación objetivo se recomienda elaborar una gráfica como la de la figura 9.14. Las conclusiones extraídas de la figura 9.14 pueden extrapolarse al caso F). En la figura 9.15 se representa un análisis similar al mostrado en la figura 9.14, pero para el caso D) variando N, el cual utiliza como señales de entrada, además de la velocidad, la dirección en magnitud angular del viento. Las conclusiones extraídas de la figura 9.15 son similares a las señaladas para la figura 9.14. Sin embargo, si se comparan las tendencias medias de la variación del error de ambas figuras se observa que los

porcentajes de disminución del error son mayores cuando se usan como señales de entrada a las ANNs las direcciones del viento en forma angular.

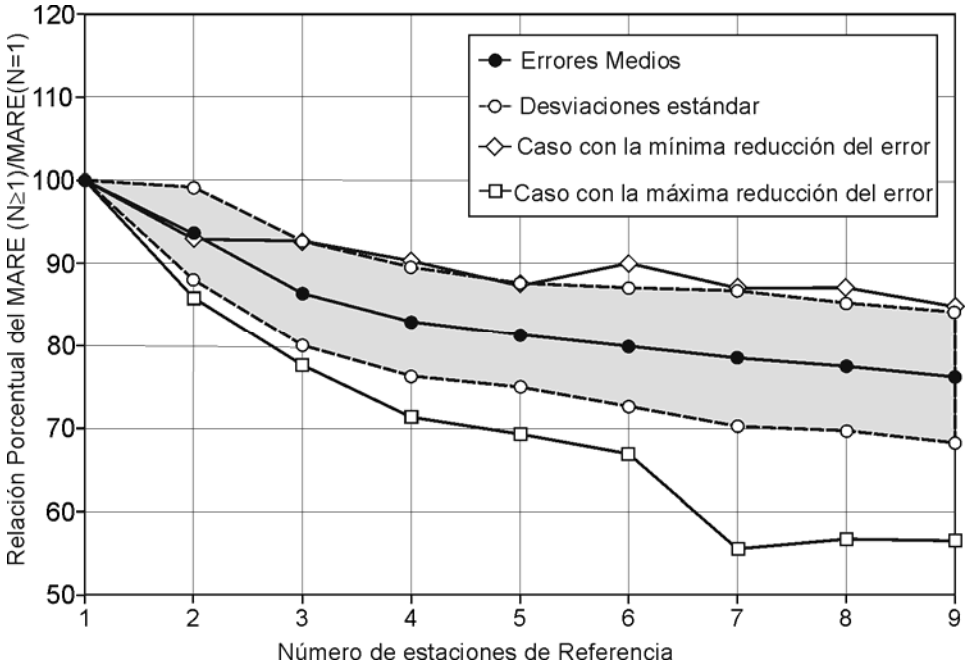

Figura 9.15: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso D) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo.

En el eje de ordenadas de la figura 9.16 se muestra el porcentaje del cociente entre el MARE obtenido en los casos E y D) y el MARE obtenido cuando se emplea una sola estación de referencia con señales de entrada de solo velocidad. De dicha figura se desprende que si se utilizan señales de entrada de velocidad y dirección angular del viento el número de estaciones de referencia que se precisan para lograr una cierta magnitud de la métrica es inferior al número de estaciones que se requieren si las señales de entrada son solo de velocidad del viento.

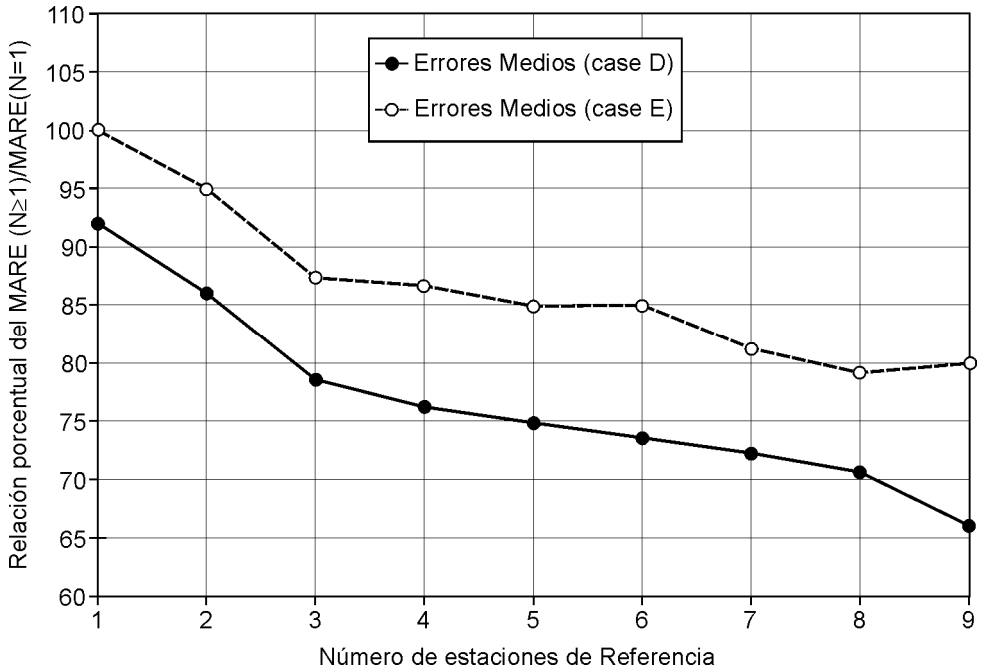

Figura 9.16: Porcentaje del cociente entre el MARE obtenido cuando se usan N estaciones de referencia (caso D y caso E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso A), frente al número de estaciones de referencia N utilizadas en la estimación de la velocidad del viento en una estación objetivo.

En el eje de abscisas de la figura 9.17 se representan las diversas estaciones analizadas en este capítulo. En el eje de ordenadas se compara el MARE mínimo obtenido al variar N en la estimación de la densidad de potencia eólica y el MARE obtenido en dicha estimación cuando se utiliza una única estación de referencia (caso B). Al error de este último caso le hemos asignado el valor 100%. Ello permite comparar los errores cometidos en la estimación de la densidad de potencia eólica cuando se utiliza una sola estación de referencia con los errores producidos en las siguientes dos hipótesis: 1) cuando se utiliza el número óptimo de estaciones de referencia, pero empleando solamente señales de velocidad y 2) cuando se utiliza el número óptimo de estaciones de referencia, pero usando señales de velocidad y dirección (en magnitud angular) del viento.

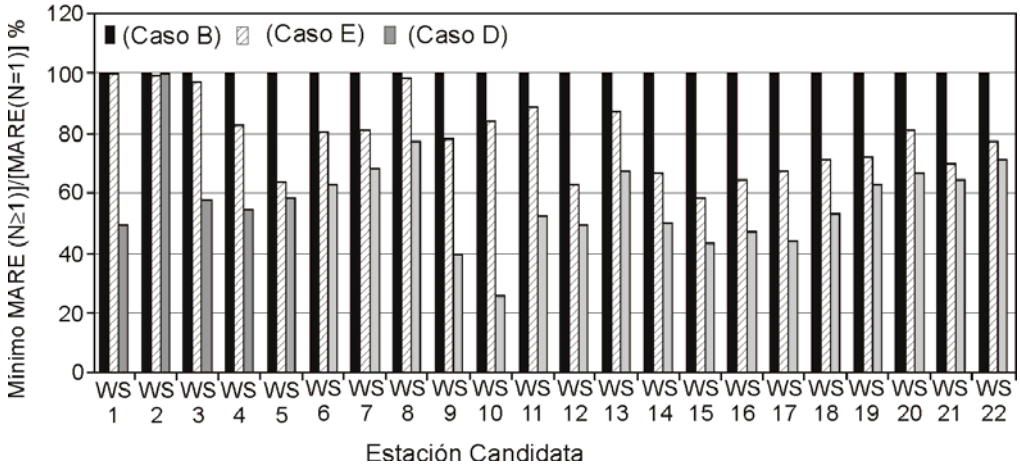

Figura 9.17: Porcentaje del cociente entre el MARE mínimo obtenido al analizar las densidades de potencia media del viento en los casos D) y E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), en función de la estación objetivo considerada.

Puede observarse en la figura 9.17 que para todas las estaciones analizadas, el mínimo error se consigue cuando se emplean varias estaciones de referencia y las ANNs son alimentadas con señales de velocidad y dirección del viento.

Dada la relación potencial existente entre la densidad de potencia eólica y la velocidad del viento, pequeñas reducciones en los errores de estimación de esta última originan significativas reducciones en la estimación de la primera. En la figura 9.18 se representa un análisis similar al presentado en la figura 9.17, pero en la estimación de la energía eléctrica generada por las cinco turbinas eólicas consideradas (Fig. 9.4).

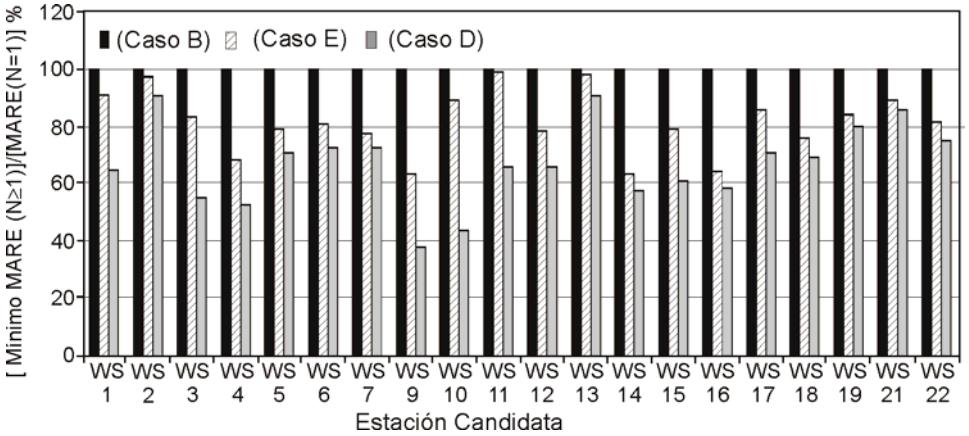

Figura 9.18: Porcentaje del cociente entre el MARE mínimo obtenido al analizar las potencias eléctricas medias generadas por los aerogeneradores en los casos D) y E) y el MARE obtenido cuando se emplea una sola estación de referencia (caso B), en función de la estación objetivo considerada.

En la elaboración de la figura 9.18 solamente se han considerado como estaciones candidatas aquellas cuya velocidad media anual es igual o superior a 5 m/s. Hay que señalar que no se han detectado diferencias significativas entre los errores generados por las diferentes turbinas eólicas utilizadas. Las conclusiones obtenidas después de analizar los resultados son similares a las expresadas para el caso de la estimación de la densidad de potencia eólica.

9.5.1 Conclusiones al capítulo

En este capítulo se han presentado los resultados de un estudio llevado a cabo en el Archipiélago Canario para analizar la influencia que las características de las señales de entrada de los modelos de ANNs tienen en la estimación de tres variables de la estación candidata. Dichas variables han sido: a) las velocidades medias horarias del viento, b) las densidades de potencias medias horarias del viento y c) las potencias eléctricas medias horarias generadas por cinco turbinas eólicas que pudiesen ser instaladas en el lugar candidato.

De la aplicación de la metodología anteriormente expuesta a un conjunto de estaciones anemométricas instaladas en las Islas Canarias se obtienen una serie de conclusiones que pueden servir de ayuda en la utilización de modelos de ANNs para estimar el potencial energético eólico de un sitio en el que no se dispone de registros de la velocidad del viento a largo plazo. Del estudio realizado se concluye que:

a) cuando se ha utilizado la dirección del viento en magnitud angular como señal de entrada de las ANNs, las métricas obtenidas presentan mejores resultados que los obtenidos cuando dicha señal de dirección es obviada. Dicha disminución de los errores es apreciable fundamentalmente cuando los Rs existentes entre la estación candidata y las de referencia no son altos; b) para valores de R comprendidos entre 0.6 y 0.9 los modelos que descomponen la velocidad en sus componentes cartesianas presentan en la mayoría de los casos peores métricas que los modelos que usan la dirección del viento en magnitud angular como señal de entrada; c) los errores de estimación tienden a disminuir al incrementarse el número de estaciones de referencia utilizadas. Sin embargo, no todas las estaciones de referencia añadidas mejoran los resultados. Por tanto, se propone que se realicen gráficas como las indicadas en la Fig.9.15 al objeto de determinar las estaciones de referencia que proporcionar el mínimo error de estimación; d) si se utilizan señales de entrada de velocidad y dirección angular del viento el número de estaciones de referencia que se precisan para lograr una cierta magnitud de la métrica es inferior al número de estaciones que se requieren si las señales de entrada son solo de velocidad del viento.

CAPITULO 10

Utilización de las Redes Bayesianas en la estimación de la potencia generada por una Turbina Eólica en un emplazamiento candidato.

INDICE

10 UTILIZACIÓN DE LAS REDES BAYESIANAS EN LA ESTIMACIÓN DE LA POTENCIA GENERADA POR UNA TURBINA EÓLICA EN UN EMPLAZAMIENTO CANDIDATO 219
10.1 Introducción. 219
10.2 MCP métodos usados para comparación 221
10.2.1 Método de Derrick 222
10.2.2 .Método de Nielsen y Otros. 223
10.3 Método Propuesto 224
10.3.1 Las Redes Bayesianas 224
10.3.2 El proceso de aprendizaje en las Redes Bayesianas 225
10.3.3 Clasificadores en las Redes Bayesianas 226
10.4 Datos Meteorológicos utilizados 227
10.5 Metodología. 232
10.5.1 Metodología para aprender y evaluar los modelos 232
10.5.2 Metodología del análisis 234
10.6 Parámetros estimados por el método de los bins 235
10.7 Métricas de evaluación utilizadas 236
10.8 Resultados del Análisis 237
10.9 Conclusiones 245

10 UTILIZACIÓN DE LAS REDES BAYESIANAS EN LA ESTIMACIÓN DE LA POTENCIA GENERADA POR UNA TURBINA EÓLICA EN UN EMPLAZAMIENTO CANDIDATO

10.1 Introducción.

Como indican Hiester and Pennell,1981 [6], la variabilidad interanual de la velocidad del viento en un emplazamiento es una cuestión importante. La energía obtenible con una turbina eólica, y por tanto, la viabilidad económica del proyecto, será muy sensible a la velocidad de viento que actúa sobre la turbina eólica durante la vida útil de la instalación.

En ocasiones no se dispone de series históricas de medidas de datos de viento en el sitio candidato que permitan evaluar la viabilidad económica de la inversión que se pretende realizar en la instalación de un sistema de conversión de energía eólica (WECS). Una opción para subsanar el inconveniente de la escasez de datos en el sitio candidato es llevar a cabo una campaña de medidas de datos eólicos que abarque un número suficiente de años. Según Hiester and Pennell [6], es difícil de estimar con cierta precisión los valores medios del comportamiento del viento con menos de 10 años de datos en el sitio candidato. Esta opción supone incrementar el costo involucrado en la campaña de medida y, fundamentalmente, posponer durante un tiempo, normalmente no aceptable, la toma de decisiones.

Otra opción consiste en estimar, mediante métodos estadísticos, el comportamiento medio interanual del viento del sitio candidato. Dichos métodos confían en la existencia de estaciones de referencia instaladas en sitios cercanos, que dispongan de medidas de recursos eólicos de larga duración. Asimismo, los mencionados métodos requieren de la realización de una campaña de medida de datos de viento durante un periodo relativamente corto (normalmente un año) en el sitio candidato. Además, ellos precisan que una porción de los datos de viento de la estación de referencia se hayan medido durante un periodo de tiempo que ha de coincidir en longitud y fecha con el periodo de medida del sitio candidato.

Para diversos autores [9,18,20,32.87,163,171,172], La primera preocupación a la hora de estudiar el potencial eólico de un emplazamiento es el disponer de la velocidad media a largo plazo (varios años). Por ello se han propuesto métodos para estimar dicha velocidad media. Putnam [171] usó un procedimiento para estimar la media de la velocidad del viento a largo plazo $\overline{V}_c^{LT}$ en un sitio candidato, a partir del conocimiento de la media de la velocidad del viento determinada durante un periodo corto $\overline{V}_c^{ST}$. Dicho método se conoce como el método de los ratios [18,20,32] y viene dado por la Ec 10-1

(Ec 10-1) $\bar{V}_c^{LT} = \bar{V}_c^{ST}\left[\bar{V}_r^{LT} / \bar{V}_r^{ST}\right]$

$\bar{V}_r^{LT}$ es la media a largo plazo en el sitio de referencia y $\bar{V}_r^{ST}$ es la media a corto plazo del sitio de referencia (para el periodo coincidente con el de $\bar{V}_c^{ST}$).

Conrad and Pollak [20] han enumerado los requisitos que se han de cumplir para poder aplicar el método de los ratios. El principal requisito es equivalente, desde el punto de vista matemático, a la exigencia de una alta correlación espacial entre las velocidades de viento del sitio candidato y las del sitio de referencia. Corotis [6,18,32,87,163], basándose en la hipótesis que las velocidades medias en el sitio candidato y en el de referencia se distribuyen según una ley normal, propone un método que incluye explícitamente el coeficiente de correlación espacial ρ^{LT} entre ambos sitios y las desviaciones estándar en el sitio candidato σ_c^{LT} y en el sitio de referencia σ_r^{LT}, (Ec 10-2)

(Ec 10-2) $\bar{V}_c^{LT} = \bar{V}_c^{ST} + \rho^{LT}\left[\bar{V}_r^{LT} - \bar{V}_r^{ST}\right]\left[\sigma_c^{LT} / \sigma_r^{LT}\right]$

Los valores de ρ^{LT}, σ_c^{LT} no se conocen y han de estimarse. En la hipótesis de que la correlación varía poco a lo largo del tiempo, en lugar de la correlación a largo plazo se suele utilizar la correlación a corto plazo. Daniels and Schroeder [163], realizan una serie de hipótesis para estimar σ_c^{LT}.

En la literatura científica se han propuesto otros métodos para abordar el problema que se presenta en un sitio con pocas medidas del recurso eólico [16,21,162,173]. Sin embargo, el método estadístico que ha sido utilizado más ampliamente en los últimos 20 años es el Measure-Correlate-Predict (MCP) [11-15]. Existen diversas variantes del método, pero todos se basan en la existencia de correlaciones estadísticas entre dos series temporales de datos y tratan de modelar la relación entre datos eólicos (velocidad y dirección) medidos en el sitio candidato durante un periodo corto de tiempo (normalmente un año) y los datos eólicos medidos simultáneamente en un sitio de referencia. Introduciendo en el modelo los datos eólicos a largo plazo (normalmente varios años) medidos en el sitio de referencia, se estiman las series de datos eólicos a largo plazo en el sitio candidato.

En las últimas décadas se ha subrayado el término minería de datos [164] para referirse al proceso de extraer conocimiento útil y compresible de forma automática o semiautomática

(asistida) de un conjunto de datos [174]. La minería de datos integra numerosas técnicas de análisis de datos y extracción de modelos. En este estudio, se propone el uso de una de estas técnicas, las redes probabilísticas bayesianas (BNs) [28,164,174,176], para estimar la distribución de frecuencias (denominada histogramas) de las velocidades a largo plazo en un sitio con pocas medidas del recurso eólico. El método propuesto permite utilizar múltiples estaciones de referencia con una larga historia de medidas de la velocidad y dirección del viento. Es decir, el método propuesto puede involucrar información regional del recurso eólico. El modelo se ha implementado en el software de libre distribución y difusión (licencia GNU), denominado Weka (Waikato Environment for Knowledge Analysis) [164], el cual ha sido desarrollado por la Universidad de Waikato (Nueva Zelanda). El sistema inteligente utilizado, cuya base de conocimiento es una función de probabilidad conjunta de todas las variables del modelo, emplea técnicas eficientes del cálculo de probabilidades condicionadas para realizar el razonamiento. Ello permite realizar de forma eficiente el aprendizaje automático del modelo y la inferencia a partir de la evidencia disponible. Con el histograma estimado de velocidades de viento a largo plazo y la curva de potencia de una turbina eólica es posible determinar la energía eléctrica media generada a largo plazo por dicha turbina eólica, utilizando el método de los bines [83], o una función de densidad de probabilidad que se ajuste al histograma [54,90]. El método propuesto en este estudio se aplicará a 4 estaciones meteorológicas ubicadas en el archipiélago canario (España). De dichas estaciones se dispone de diez años de datos medios horarios de velocidad y dirección del viento. Para estimar la bondad de los modelos de estimación propuestos se han comparado los errores generados con los mismos con los errores de dos algoritmos MCP que han sido evaluados [11,162]: Un Método de regresión lineal y un método de regresión vectorial.

Para ello se han utilizado diferentes métricas. Estás métricas caracterizan la estimación de (1) el correcto histograma de frecuencias relativas acumuladas de la velocidad del viento, (2) la correcta densidad de potencia media del viento, y (3) la correcta producción de energía media anual. Para este último análisis se han utilizado dos aerogeneradores comerciales. Las potencias nominales de estos aerogeneradores son de 330 y 800kW [165]

10.2 MCP métodos usados para comparación

Los métodos de Derrick A. [12] y Niesel et al. [11] han sido elegidos para comparar sus resultados con el método alternativo basado en BN propuesto por los autores.

10.2.1 Método de Derrick

Derrick [12] usa una regresión lineal para caracterizar la relación entre las velocidades del viento del sitio candidato (c) y del sitio de referencia (r) a largo plazo (LT), Ec 10-3. A este método lo referenciaremos en este estudio con el nombre de regresión lineal (LR)

(Ec 10-3) $$\left(v_j\right)_c^{LT} = a\left(v_j\right)_r^{LT} + b$$

$\left(v_j\right)_c^{LT}$ son las velocidades del viento estimadas en el sitio candidato, $\left(v_j\right)_r^{LT}$ son las velocidades del viento medidas en el sitio de referencia, a y b son la pendiente y la ordenada en el origen (offset) obtenidas de la regresión lineal [77] Ec 10-4.

(Ec 10-4) $$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^{n}\left(v_i^2\right)_r^{ST} & \sum_{i=1}^{n}\left(v_i\right)_r^{ST} \\ \sum_{i=1}^{n}\left(v_i\right)_r^{ST} & n \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n}\left(v_i\right)_c^{ST}\left(v_i\right)_r^{ST} \\ \sum_{i=1}^{n}\left(v_i\right)_c^{ST} \end{bmatrix}$$

En la Ec 10-4 $\left(v_i\right)_r^{ST}$ y $\left(v_i\right)_c^{ST}$ son las velocidades medias horarias del viento a corto plazo (ST) en el sitio de referencia y en el sitio candidato, respectivamente. *n* es el número de datos de velocidad del viento.

Generalmente, el método de los bines agrupa la velocidades del viento horarias en función de la dirección en el sitio de referencia. Para ello, los datos son divididos en un determinado número de sectores de dirección, que normalmente son ocho de 45º o 12 de 30º. Entonces, se estiman los parámetros *a* y *b* del modelo, (Ec 10-4), para cada sector de dirección. Es decir, *a* y *b* dependen de la velocidad del viento y de la dirección. Por tanto, *n* en Ec 10-4 es el número de velocidades de viento en el sector de dirección del sitio de referencia que se esté analizando.

El Software Mathcad 2001*i* de MathSoft Engineering & Education, Inc [142] fue utilizado para la implementación de este método.

10.2.2 .Método de Nielsen y Otros.

Nielsen y otros, 2001 proponen descomponer las velocidades del viento del sitio de referencia y del candidato según dos ejes cartesianos (x,y) [107] y llevar a cabo una regresión bidimensional, Ec 10-5. Este método es referido aquí como método de regresión vectorial (VR).

(Ec 10-5)
$$\begin{bmatrix} \left\{ (v_x)_i \right\}_c^{LT} \\ \left\{ (v_y)_i \right\}_c^{LT} \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} \left\{ (v_x)_i \right\}_r^{LT} \\ \left\{ (v_y)_i \right\}_r^{LT} \end{bmatrix}$$

Los coeficientes a_{ij} y b_j se determinan usando una regresión lineal, separadamente para los distintos sectores de dirección de la velocidad del viento que se consideren. Es decir, para cada sector se estiman los coeficientes mediante el producto matricial indicado en la Ec 10-6

$$\begin{bmatrix} b_1 & b_2 \\ a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} n & \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_r^{ST})_x \right\}_i^{2} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \left\{ (v_x)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_r^{ST} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i^2 \right\}_r^{ST} \end{bmatrix}^{-1}$$

(Ec 10-6)

$$\begin{bmatrix} \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} \left\{ (v_x)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \left\{ (v_x)_i \right\}_r^{ST} \\ \sum_{i=1}^{n} \left\{ (v_x)_i \right\}_c^{ST} \left\{ (v_y)_i \right\}_r^{ST} & \sum_{i=1}^{n} \left\{ (v_y)_i \right\}_c^{ST} \left\{ (v_y)_i \right\}_r^{ST} \end{bmatrix}$$

Los módulos de cada una las velocidades estimadas a largo plazo en la estación candidata se determinan mediante Ec 10-7

(Ec 10-7) $$\left(v_i\right)_c^{LT} = \left[\left\{\left(v_x\right)_i^2\right\}_c^{LT} + \left\{\left(v_y\right)_i^2\right\}_c^{LT}\right]$$

Las direcciones a largo plazo pueden obtenerse a partir de las componentes según los ejes x e y de las velocidades estimadas a largo plazo haciendo uso de la Ec 10-7. [107]

El Software Mathcad 2001*i* de MathSoft Engineering & Education, Inc [142] fue utilizado para la implementación de este método.

10.3 Método Propuesto

10.3.1 Las Redes Bayesianas

Las redes probabilísticas son sistemas inteligentes basados en probabilidad que utilizan modelos que permiten tratar problemas con incertidumbre [177] y que pueden involucrar a un elevado número de variables [28,164,175]. Las redes probabilísticas utilizan grafos [176] y funciones de probabilidad para definir modelos que cumplan un conjunto de relaciones de dependencia entre las variables. En función del tipo de grafo utilizado (no dirigido, dirigido, mixto) y de la forma de establecer las relaciones de dependencia en el mismo, se obtienen diferentes tipos de redes probabilísticas. En el presente estudio proponemos la utilización de redes bayesianas (BN). Las BN (grafos dirigidos) son más complejas que las redes de Markov (grafos no dirigidos) [177] pero son más potentes, ya que permiten relaciones de dependencia más generales [176].

Sea *U*=(X_1, ….,X_N) un conjunto finito de variables aleatorias. Supongamos que dichas variables son las velocidades y direcciones del viento registradas durante un determinado periodo de tiempo en un conjunto de estaciones anemométricas instaladas en una región dada. Una red Bayesiana (BN) sobre el conjunto de variables *U* es un modelo basado en un par, BN=(DAG, Θ), que relaciona el conjunto de variables de *U*. El DAG es un grafo acíclico[1] dirigido (véanse las figuras 10.10 a 10.13), donde cada nodo o vértice representa a una de las variables aleatorias X_1, ….,X_N y cada arco dirigido (flecha) entre dos nodos, representa la relación probabilística entre las variables que conecta. Es decir, el DAG define la estructura de la red bayesiana. La ausencia de un arco entre dos nodos implica que no existe dependencia probabilística directa entre dichos nodos o variables. Si existe un arco que une un nodo A con

[1] El grafo no tiene ciclos. Es decir, no existe un camino directo que empiece y termine en un mismo nodo.

otro nodo B, A es denominado un padre de B y B es llamado un hijo de A. Se suele utilizar el símbolo π_i para indicar los nodos padres de la variable X_i.

El DAG codifica consideraciones de independencia. Es decir, cada variable X_i es independiente de sus no descendientes dados sus padres en el DAG. El segundo componente del par, denominado Θ, representa el conjunto de distribuciones de probabilidad $p(X_i/\pi_i)$ para cada variable (desde i=1 hasta N) que cuantifica la red. La estructura de dependencia/independencia mostrada por el DAG puede ser expresada en términos de la función de probabilidad conjunta (JPD) mediante el producto de las distribuciones condicionadas. Es decir, una BN define una única JPD sobre *U* dada por Ec 10-8 [177].

(Ec 10-8) $$p(X_1, X_2, \ldots, X_N) = \prod_i p(X_i/\pi_i)$$

Dependiendo del carácter discreto o continuo de las variables, las probabilidades condicionadas en Ec 10-8 son familias específicas. En este estudio, de los tres tipos de BN que en principio pueden considerarse (Gaussianas, Multinomiales y Mixtas) [176], se utilizarán las redes bayesianas multinomiales. Es decir, se considera que todas las variables son discretas y que, por tanto, tienen un número finito de posibles estados. Además, las distribuciones de probabilidad asociadas a cada variable (nodo) vienen dadas, ya sea de forma paramétrica o numérica, por medio de tablas que asignan valores numéricos a las diferentes combinaciones de las variables.

10.3.2 El proceso de aprendizaje en las Redes Bayesianas

La naturaleza dual de las BN da lugar a que el aprendizaje de las mismas se lleve a cabo en un proceso de dos etapas [178]: el primer paso consiste en aprender la estructura de la BN. Es decir, a partir de un conjunto de datos[2] D, establecer las relaciones de dependencia entre las variables y obtener le grafo que mejor los represente. El segundo paso consiste en el aprendizaje paramétrico. Es decir, en obtener las probabilidades a priori y condicionales requeridas de acuerdo con la estructura del grafo, los datos y el tipo de BN elegida.

El conjunto de redes bayesianas con N nodos es de orden super-exponencial, con lo que la enumeración exhaustiva del conjunto de redes para encontrar la mejor candidata no es factible.

[2] Por ejemplo las velocidades y direcciones registradas en m=M/2 estaciones anemométricas de una región durante corto tiempo (ST)

La búsqueda de la estructura que optimiza el conjunto de datos es un problema NP- completo (intratable)- [178] y necesita algoritmos eficientes [28] que, aunque no garanticen la localización del óptimo, no tengan un coste de cálculo elevado. Existen diversos métodos de aprendizaje, sin embargo, los más sencillos son los algoritmos iterativos de búsqueda, que constan de dos partes. Una parte que mide la calidad de cada red candidata y la otra parte que utiliza un algoritmo de búsqueda que explora el conjunto de grafos posibles con el objetivo de encontrar una BN de buena calidad.

10.3.3 Clasificadores en las Redes Bayesianas

Los clasificadores en las Redes Bayesianas [180] constituyen una de las más exitosas aplicaciones de las redes Bayesianas. En este caso especial de red Bayesiana hay una variable, que denominamos variable clase y que es la única variable que no tiene padres en la estructura, y un conjunto de variables que denominados variables atributos (Fig.10.10 a 10.13). El objetivo de la clasificación es predecir correctamente el valor de la variable clase C (por ejemplo, la velocidad del viento en un determinado lugar candidato) que puede tener *k* posibles valores discretos ($c_1,\ldots c_k$) (por ejemplo, 0.5 m s^{-1}, 1.5 m s^{-1}, 2.5 m s^{-1},…. *Nb*-0.5 m s^{-1}) dado un conjunto ($A_1,\ldots A_{N-1}$) de variables predictoras o variables atributos (por ejemplo, velocidades y direcciones del viento en las estaciones de referencia), también discretas (por ejemplo, 0.5 m s^{-1}, 1.5 m s^{-1}, 2.5 m s^{-1},…. *Nb*-0.5 m s^{-1} , 0º, 45º, 90º,….,315º). Es decir, se pretende identificar el valor de la variable C más plausible y devolverlo como resultado de la clasificación. En el contexto bayesiano la hipótesis más plausible es aquella que tiene la máxima probabilidad a posteriori dados los atributos. Esta hipótesis se la conoce como la hipótesis máxima a posteriori MAP. Por tanto, el valor c_{MAP} a devolver será el argumento (arg) de la máxima probabilidad a posteriori, (Ec 10-9)

(Ec 10-9) $$c_{MAP} = \underset{c\in\Omega_C}{\arg\max}\ p\left(c/A_1\ldots A_{N-1}\right)$$

Donde Ω_C es el conjunto de valores discretos que puede tomar la variable clase C y $p\left(c/A_1\ldots A_{N-1}\right)$ es la probabilidad a posteriori de la clase c.

El cálculo de $p\left(c/A_1\ldots A_{N-1}\right)$ puede llevarse a cabo utilizando el teorema de Bayes, (Ec 10-10)

$$\text{(Ec 10-10)} \quad c_{MAP} = \underset{c \in \Omega_C}{\arg\max}\ p\left(c/A_1 \ldots A_{N-1}\right) = \underset{c \in \Omega_C}{\arg\max} \frac{p\left(A_1 \ldots A_{N-1}/c\right) p(c)}{p(A_1 \ldots A_{N-1})}$$

Donde $p(c)$ es la probabilidad a priori de la clase c, $p(A_1 \ldots A_{N-1})$ la probabilidad marginal y $p\left(A_1 \ldots A_{N-1}/c\right)$ la probabilidad condicional de la clase c.

Dado que el divisor de la Ec 10-10 será el mismo para todas las categorías se puede eliminar, obteniéndose la Ec 10-11

$$\text{(Ec 10-11)} \quad c_{MAP} = \underset{c \in \Omega_C}{\arg\max}\ p\left(A_1 \ldots A_{N-1}/c\right) p(c)$$

Teniendo en cuenta la red Bayesiana, Ec 10-8, se puede expresar la Ec 10-11 de la siguiente manera, Ec 10-12,

$$\text{(Ec 10-12)} \quad c_{MAP} = \underset{c \in \Omega_C}{\arg\max}\ p\left(A_1 \ldots A_{N-1}/c\right) p(c) = \underset{c \in \Omega_C}{\arg\max}\ p\left(c\right) \prod_i p\left(A_i/\pi_i\right)$$

Weka [164] cuenta con varias medidas de calidad y de algoritmos de búsqueda. Entre las medidas usadas por Weka [164] para juzgar la calidad de la estructura, en este estudio se ha seleccionado la métrica bayesiana [83,176]. De los diversos algoritmos de búsqueda disponible en Weka [164] en este estudio se ha utilizado el denominado algoritmo K2 [181] que realiza una búsqueda voraz. La red Bayesiana usada inicialmente es una Naive Bayes Network [164,180], esto es una red con una flecha desde el nodo clasificador o nodo clase a cada uno de los otros nodos. Asimismo, se ha restringido el número máximo de padres posibles para cada nodo en 2.

Una vez que se ha aprendido la estructura de la red, Weka [164] permite elegir como aprender las tablas de probabilidad condicionadas. En este estudio se ha seleccionado el Estimador Simple , disponible en el interface gráfico más fácil de usar de Weka, denominado Explorer.

10.4 Datos Meteorológicos utilizados

Los datos meteorológicos utilizados en este estudio (velocidades y direcciones medias horarias del viento) han sido registrados durante el periodo 1999-2008 en cuatro estaciones meteorológicas instaladas en tres islas del archipiélago canario (España) (Fig. 10.1). Dicha

información nos ha sido cedida por la Agencia Estatal de Meteorología (AEMET) del Ministerio de Medio Ambiente, y Medio Rural y Marino del Gobierno de España.

En la Figura 10.1 se puede observar el nombre de las islas (Tenerife, La Palma y El Hierro), la situación geográfica de las estaciones (latitud y longitud), las distancias entre ellas (en kms), los nombres de las estaciones (Muelle de Santa Cruz, Aeropuerto de Reina Sofía, Aeropuerto de Mazo y Aeropuerto de Los Cangrejos) y las referencias dadas a cada estación meteorológica (WS-1, WS-2, WS-3 y WS-4). La altura sobre el nivel del suelo de dichas estaciones es de 10 metros, con excepción de la WS-1 cuya altura es menor.

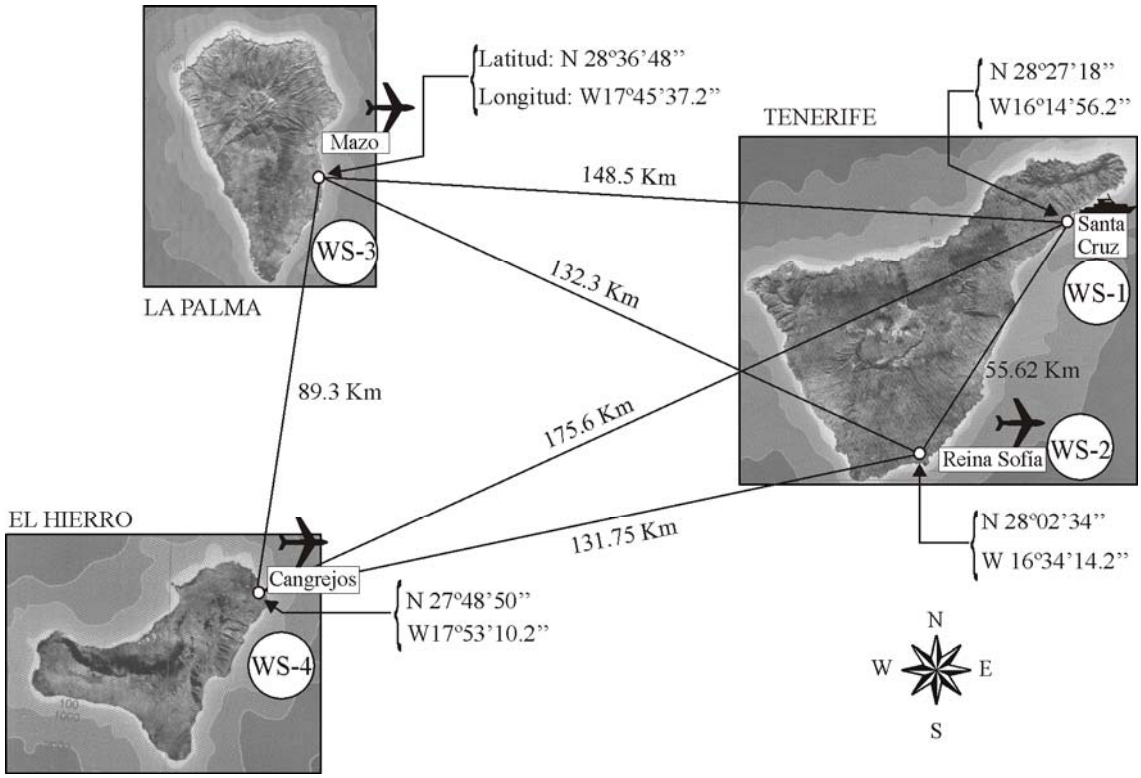

Figura 10.1:Situación geográfica de las cuatro estaciones anemométricas utilizadas.

La Figura 10.2 muestra la evolución de las velocidades medias anuales en las cuatro estaciones consideradas.

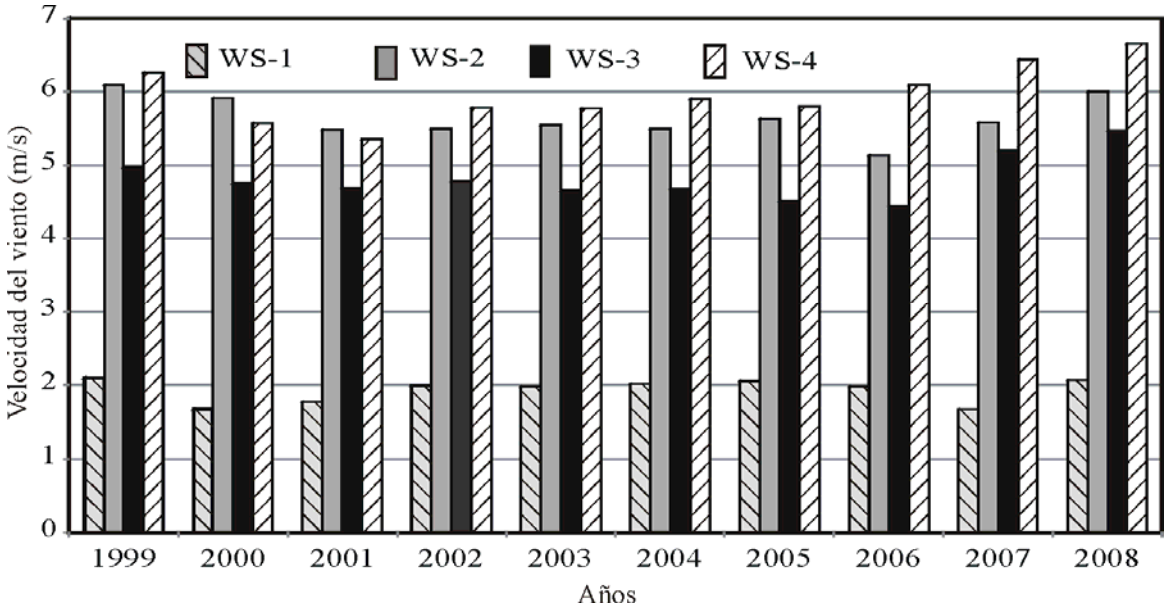

Figura 10.2:Evolución interanual de las velocidades medias anuales de la velocidad del viento en las cuatro estaciones utilizadas.

La Figura 10.3 muestra los histogramas de frecuencia relativa de la velocidad del viento de cada una de las estaciones, con anchos de bin de 1 m s^{-1}. La columna de la izquierda representa los histogramas del año 2008 y la columna de la derecha representa los histogramas construidos con las velocidades de viento) de todos los años (1999-2008). Asimismo, se muestra en cada histograma la velocidad media del viento y la desviación estándar.

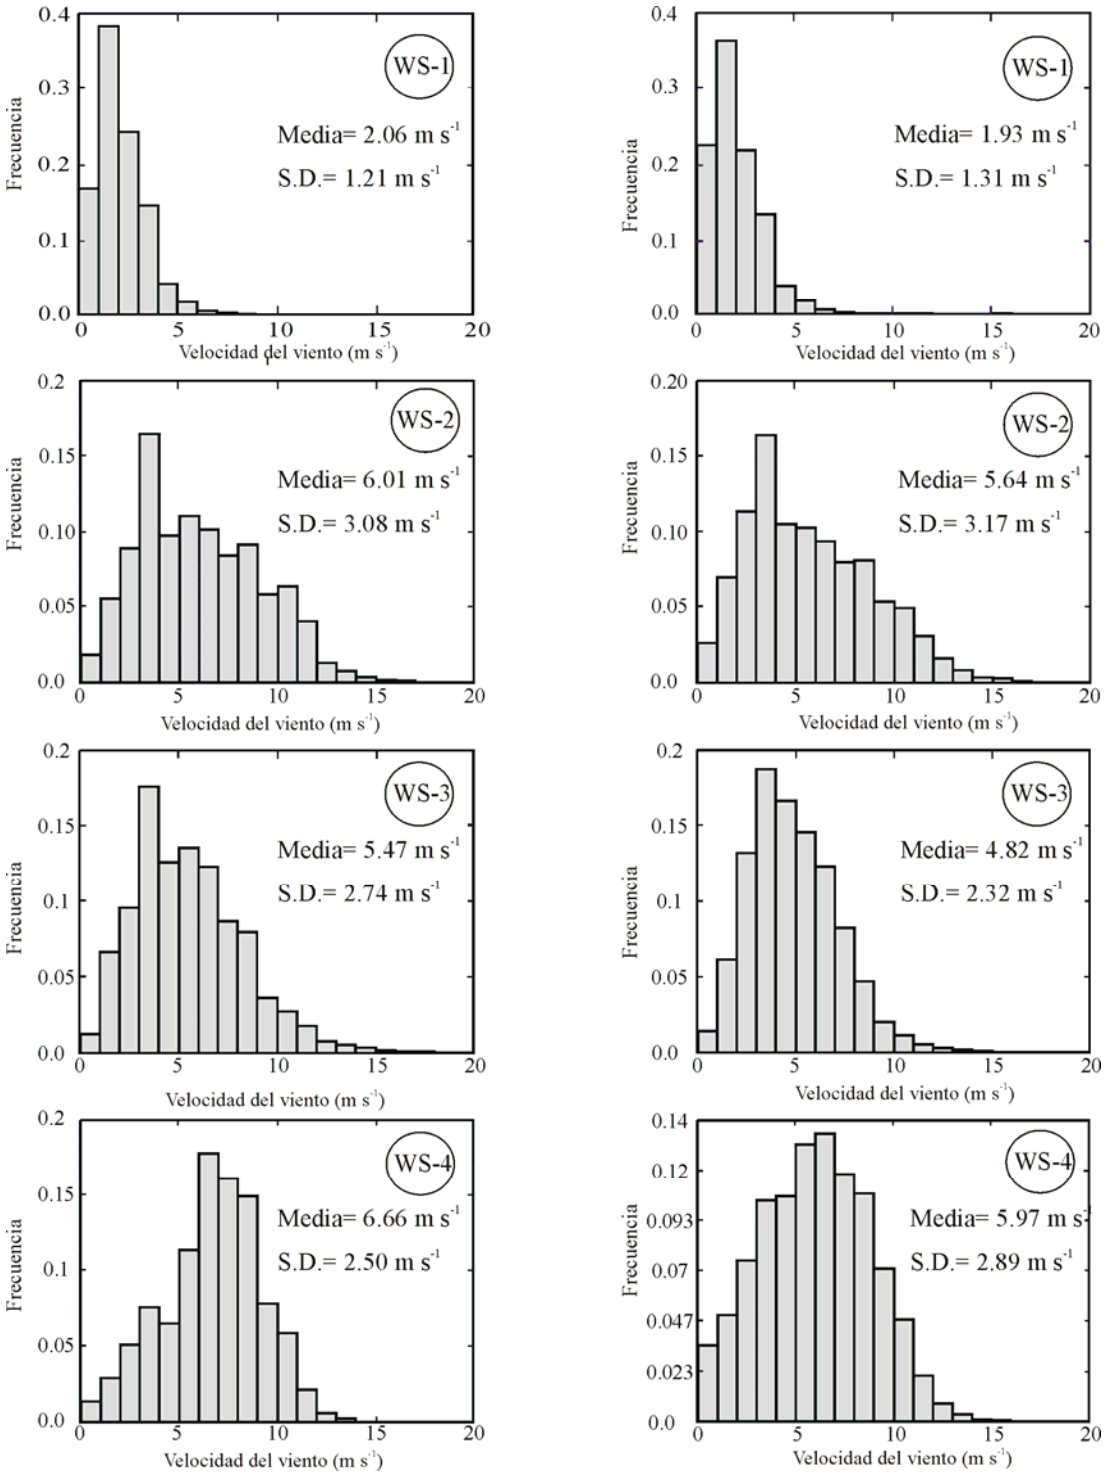

Figura 10.3:Histogramas de frecuencias relativas de la velocidad del viento en las cuatro estaciones utilizadas. La columna de la izquierda representa los histogramas del año 2008. La columna de la derecha representa los histogramas construidos con las velocidades del viento del periodo 1999-2007

La Figura 10.4 muestra las rosas de los vientos de cada una de las estaciones[3]. La columna de la izquierda representa las rosas de viento del año 2008 y la columna de la derecha representa las rosas de viento construidas con las velocidades y direcciones del viento de todos los años (1999-2008).

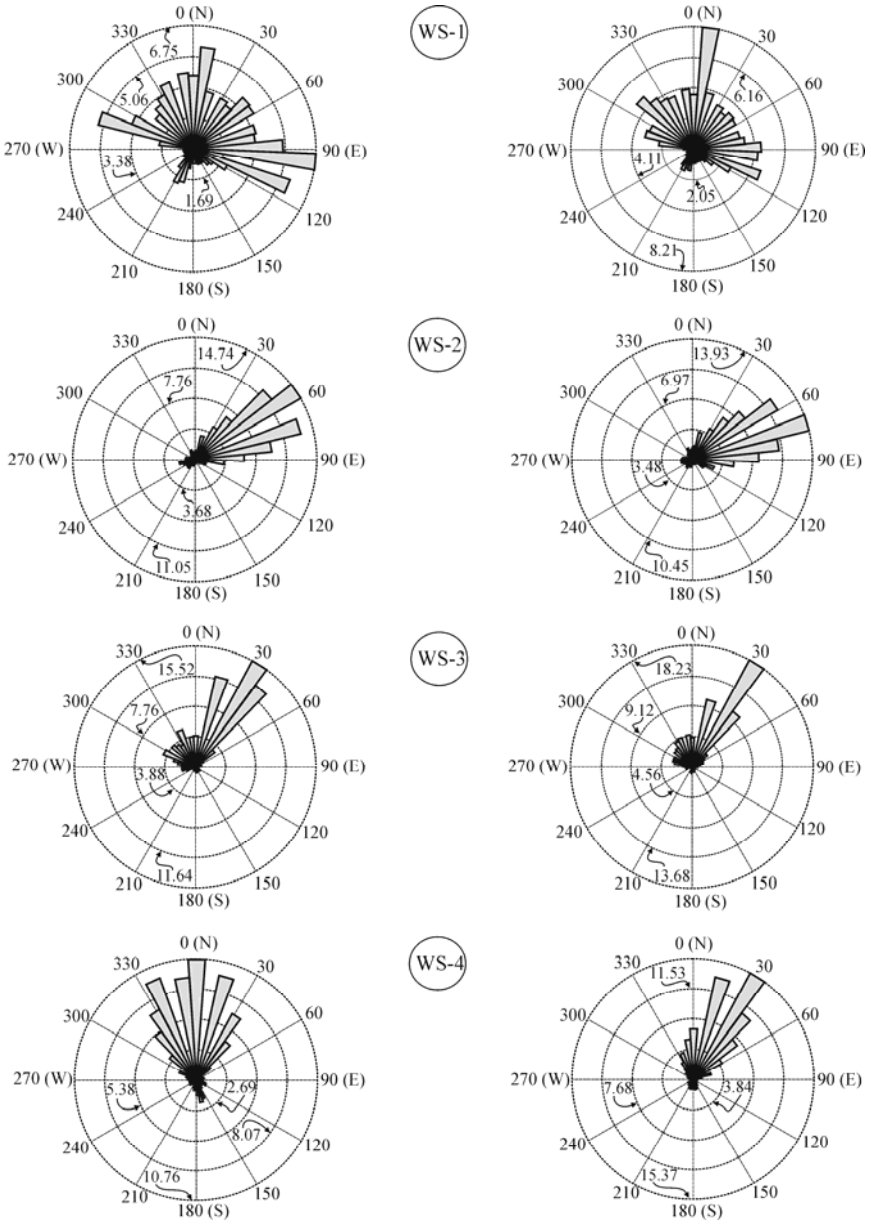

Figura 10.4:Rosas de los vientos de las cuatro estaciones utilizadas. La columna de la izquierda representa las rosas del año 2008. La columna de la derecha representa las rosas construidas con los datos de viento del periodo 1999-2008.

[3] En los análisis realizados en este estudio se han utilizado ocho sectores de direcciones. Es decir, se han dividido los 360º en sectores de 45º.

En la Tabla 10.1 se muestran los coeficientes de correlación lineal entre las velocidades del viento de las diversas estaciones. Dichos coeficientes se han obtenido para los datos de velocidad del viento del año 2008 y para el conjunto de todos los datos de velocidad del viento (1999-2008). A pesar de las relativamente cortas distancias que existen entre los puntos de ubicación de las estaciones anemométricas, debido a la orografía de las zonas donde estas estaciones están dichos coeficientes son bajos.

Tabla 10.1: Coeficientes de correlación lineal entre las velocidades de viento de las distintas estaciones anemométricas

	Datos del año 2008				Datos del periodo 1999-2008			
	WS-1	WS-2	WS-3	WS-4	WS-1	WS-2	WS-3	WS-4
WS-1	1	0.284	0.308	0.161	1	0.258	0.220	0.162
WS-2		1	0.319	0.248		1	0.377	0.259
WS-3			1	0.449			1	0.480
WS-4				1				1

10.5 Metodología.

10.5.1 Metodología para aprender y evaluar los modelos

En la figura 10.5 se muestra un esquema representativo del problema que nos ocupa. Puede observarse que existe una estación candidata de la que se dispone de un corto periodo de datos medios horarios del viento (en nuestro, del año 2008) y varias estaciones de referencia (en nuestro caso un máximo de tres) de las que se dispone de datos de velocidad y dirección media horaria del viento durante un periodo largo de tiempo (en nuestro caso, 10 años: 1999-2008). Con los modelos descritos en los apartados 2 y 3 anteriores se pretenden estimar las velocidades del viento en la estación candidata en el periodo largo desconocido. Para ello, se han de construir y evaluar los modelos a partir del conjunto de datos conocidos simultáneamente en todas las estaciones involucradas (en nuestro caso un máximo de cuatro estaciones y un mínimo de dos). Es decir, utilizando los datos de viento del periodo corto (en nuestro caso, los datos de viento del año 2008).

Como técnica de evaluación de los modelos se ha usado la validación cruzada con 10 pliegues[4](proceso señalizado en la Fig.10.5, con el número 1 encerrado en un círculo). Con esta técnica, los datos del año 2008 se dividen en diez partes. Una parte se utiliza para el conjunto de ensayo y con los datos de las nueve restantes partes se lleva a cabo el entrenamiento del modelo, el cual se usa para predecir el resultado de los datos de la parte reservada para el ensayo. Este proceso se repite diez veces, dejando cada vez una parte diferente para el ensayo. Por tanto, se construyen diez modelos y se obtienen diez errores independientes, uno por cada modelo construido. Por último, utilizando todos los datos del periodo corto (2008) como datos de entrenamiento se construye un modelo (proceso señalizado en la Fig 10.5 con el número 2 encerrado en un círculo), que se usa para predecir los datos desconocidos de la estación candidata. El error utilizado para estimar dicho modelo será la media aritmética de los diez errores obtenidos con la validación cruzada.

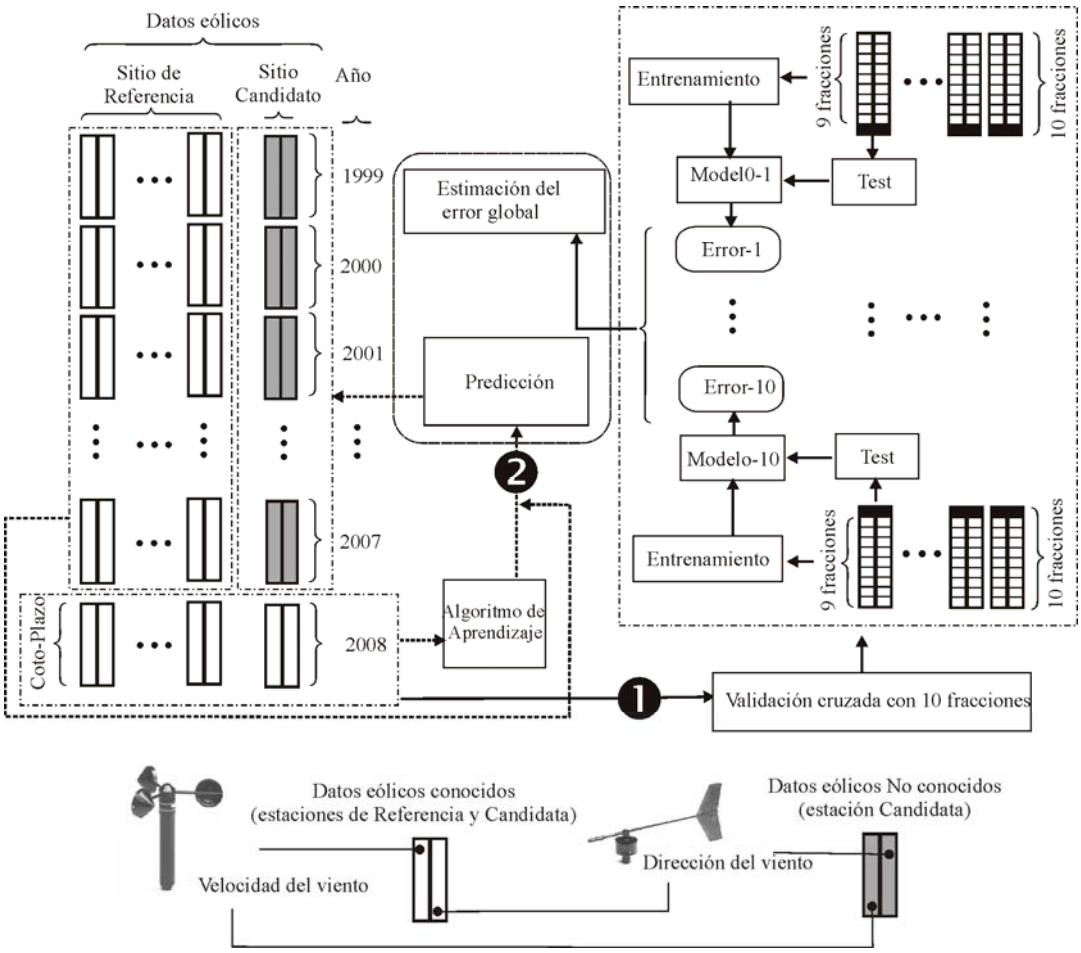

Figura 10.5:Esquema representativo de la metodología para aprender y evaluar los modelos

[4] 10 La Validación Cruzada ha llegado a ser, en la práctica, un método estándar [164]

10.5.2 Metodología del análisis

El procedimiento de análisis se compone de dos etapas. En la primera etapa del procedimiento metodológico utilizado en este estudio, para cada estación anemométrica, se evalúan los distintos modelos que pueden generarse con el método propuesto (Redes Bayesianas) y con los métodos utilizados para comparación (Método de regresión lineal y método de regresión vectorial). Dicha evaluación consiste en comparar los errores generados por los modelos utilizando la validación cruzada (Fig 10.5). Dichos errores valoran la eficacia de cada método en la estimación del histograma de frecuencias acumuladas de la velocidad del viento y se miden con las métricas indicadas en el apartado 7.

El número de modelos que pueden generarse con las redes Bayesianas, en cada una de las cuatro estaciones anemométricas, depende del número de estaciones de referencia elegidas. Por tanto, el número de modelos que se pueden construir para cada estación candidata se obtiene de la combinación $C(nr,r)$ de nr estaciones de referencia tomadas r a la vez Ec 10-13

$$\text{(Ec 10-13)} \quad C(nr,r) = \binom{nr}{r} = \frac{nr!}{r!(nr-r)!}$$

Un modelo se obtendrá de tomar las tres estaciones de referencia a la vez, otros modelos serán combinaciones de las tres estaciones tomadas dos a la vez y los restantes modelos serán combinaciones de las tres estaciones tomadas una a la vez. Por tanto, se obtendrá un modelo con tres estaciones de referencia, 3 modelos con dos estaciones de referencia y 3 modelos con una estación de referencia. La utilización de un alto número de estaciones de referencia no tiene porqué implicar la obtención de un mejor modelo. Los modelos pueden ser sensibles a la presencia de variables redundantes o irrelevantes. Por ello, se pretenden analizar modelos con diferentes combinaciones de estaciones de referencia. El número de modelos obtenidos con los métodos MCP de comparación elegidos será de tres por cada método y estación.

En la segunda etapa del procedimiento, en primer lugar se seleccionan los modelos de cada estación que, según las métricas utilizadas, han generado menores errores. Es decir, de los modelos generados con BN se selecciona el modelo que utiliza tres estaciones de referencia, el mejor de los modelos generados con dos estaciones de referencia y el mejor modelo generado con una estación de referencia. Respecto de los modelos MCP de comparación, se elegirá el mejor de cada método y estación anemométrica. En segundo lugar, con los modelos

seleccionados se procede a estimar los histogramas de frecuencia de la velocidad del viento a largo plazo de las cuatro estaciones candidatas. Posteriormente, se comparan los valores estimados con los valores disponibles u observados a largo plazo en dichas estaciones candidatas. Los parámetros analizados en dicha comparación se indican en el apartado 6 y las métricas utilizadas en su evaluación se señalan en el apartado 7.

10.6 Parámetros estimados por el método de los bins

Entre los métodos que básicamente se suelen utilizar para estimar la energía generada por una turbina eólica sujeta a un régimen dado de viento se encuentran los métodos estáticos o probabilísticos [90]. Los métodos estáticos son recomendados cuando se desea confirmar un emplazamiento como candidato a albergar un parque eólico. Dentro de este grupo de métodos se encuentra el método de los bines. En dicho método los datos de velocidad del viento son separados en *Nb* bines de ancho *w,* el cual suele ser de 1 m s^{-1} . En el caso de los datos de dirección del viento el intervalo de clasificación suele ser un sector de 30º o de 45º. Determinando la frecuencia relativa en que la velocidad del viento sopla en cada bin puede plotearse el histograma de frecuencias (Fig 10.3). Asimismo, puede construirse el diagrama de rosa de los vientos, el cual muestra la distribución acimutal (azimutal) de la dirección del viento (Fig 10.4)

La densidad de potencia media del viento $\overline{P}$ [141] es un indicador del potencial eólico de un emplazamiento. Si la densidad del aire ρ se considera constante e igual a su valor medio[5] y los valores de v_i (puntos medios de los anchos de los bines de la velocidad del viento) tienen unidades de m s^{-1}, entonces el valor de $\overline{P}$, en w m^{-2}, viene dado por Ec 10-14

$$\text{(Ec 10-14)} \quad \overline{P} = \frac{1}{2}\overline{\rho}\frac{\sum_{i=1}^{Nb} f_i v_i^3}{\sum_{i=1}^{Nb} f_i}$$

Como señaló Hau [85] la curva de potencia de una turbina eólica, según lo especificado por el fabricante, es la base de cálculo de la energía de salida desde el punto de vista del posible comprador. La curva de potencia de una turbina eólica PWT (v,ρ) depende de la velocidad, v, y de la densidad, ρ, del aire [141]. Sin embargo, la mayoría de los fabricantes publican las curvas

de potencia para una densidad del aire de 1,225 kg m-3. Este supuesto simplifica el cálculo de la potencia media de salida, $\overline{P}_{WT}$, para una turbina eólica en un régimen eólico determinado, (Ec 10-15)

En este estudio, la estimación de la potencia de salida para cada valor de v, se calcula mediante la interpolación de los valores de las tablas proporcionadas por los fabricantes. Como las curvas de potencia son bastante suaves, se puede aproximar mediante las medias de una interpolación cúbica spline [144]. La interpolación cúbica spline permite pasar una curva a través de un conjunto de puntos de tal manera que la primera y segunda derivadas de la curva son continuas a través de cada punto. Esta curva se monta mediante la adopción de tres puntos adyacentes y la construcción de un polinomio de tercer grado que pasa por esos puntos. Estos polinomios cúbicos luego se unen para formar la curva de completado.[6]

(Ec 10-15) $$\overline{P}_{WT} = \frac{\sum_{i=1}^{Nb} f_i PWT(v_i)}{\sum_{i=1}^{Nb} f_i}$$

10.7 Métricas de evaluación utilizadas

Con el objetivo de evaluar la bondad de cada uno de los modelos se proponen distintas métricas. Cada una de las métricas trata de caracterizar la correcta estimación de una característica del régimen de vientos. En este sentido, la métrica M1 evalúa la densidad de potencia media del viento a largo plazo, M2 y M3 la energía media generada a largo plazo por turbina eólicas de 330 kW y 800 kW de potencia nominal, respectivamente. Dichas métricas se definen por las Ec 10-16 y Ec 10-17, donde el subíndice "*p*" significa predicha y el subíndice "*o*" significa observada.

(Ec 10-16) $$M1 = \frac{\left(\overline{P}\right)_{\mathrm{p}}}{\left(\overline{P}\right)_{\mathrm{o}}}$$

(Ec 10-17) $$M2 = \frac{\left(\overline{P}_{WT-330}\right)_{\mathrm{p}}}{\left(\overline{P}_{WT-330}\right)_{\mathrm{o}}} \quad M3 = \frac{\left(\overline{P}_{WT-800}\right)_{\mathrm{p}}}{\left(\overline{P}_{WT-800}\right)_{\mathrm{o}}}$$

[5] El valor típico utilizado en la literature consutada es de $\overline{\rho}$ = 1.225 kg m^{-3}, que se corresponde con las condiciones estándares (A nivel del mar, 15ºC).

Asimismo, con el propósito de evaluar la eficacia de cada método en la estimación del histograma de frecuencias de la velocidad del viento se han propuesto diversas métricas [164]. Estás son el error absoluto medio (MAE), el error absoluto relativo (RAE), la raíz del error cuadrático medio (RMSE) y la raíz del error cuadrático medio relativo (RRSE). En las siguientes ecuaciones, F_i es el valor de la frecuencia acumulada observada (esperada), $\hat{F}_i$ es la frecuencia acumulada modelada (estimada) (donde i=1 a Nº bins) y $\overline{F}$ es la media de las frecuencia acumuladas observadas.

(Ec 10-18) $$MAE = \frac{1}{Nb}\sum_{i=1}^{Nb}\left|\hat{F}_i - F_i\right|$$

(Ec 10-19) $$RAE = \frac{\sum_{i=1}^{Nb}\left|\hat{F}_i - F_i\right|}{\sum_{i=1}^{Nb}\left|F_i - \overline{F}\right|}$$

(Ec 10-20) $$RMSE = \sqrt{\frac{1}{Nb}\sum_{i=1}^{Nb}\left(\hat{F}_i - F_i\right)^2}$$

(Ec 10-21) $$RRSE = \sqrt{\frac{\sum_{i=1}^{Nb}\left(\hat{F}_i - F_i\right)^2}{\sum_{i=1}^{Nb}\left(F_i - \overline{F}\right)^2}}$$

10.8 Resultados del Análisis

En las figuras 10.6 a 10.9 se muestran los errores obtenidos, para cada una de las cuatro estaciones, según la primera etapa de la metodología de análisis indicada en el apartado 5.2. Un valor igual a cero para estas métricas indicaría una correcta estimación de la distribución de frecuencia de la velocidad del viento acumulada.

En las cuatro estaciones analizadas se observa que el método de BN con tres estaciones de referencia (BN-3) ha proporcionado los menores errores, independientemente de la métrica utilizada. Los modelos de BN con dos estaciones de referencia (BN-2), con excepción de un modelo de WS-4 y otro de la WS-1, han proporcionado menores errores que las BNs con una

[6] Para utilizar Ec 10-14 no se ha empleado ningún modelo de extrapolación [32] de la velocidad del viento a la altura del eje del rotor de las turbinas eólicas. Ello se ha hecho así para evitar en este estudio los potenciales errores que pueden introducir dichos modelos de extrapolación.

estación de referencia (BN-1). Los métodos de comparación utilizados han proporcionado en la mayoría de los casos analizados peor comportamiento que los modelos BN propuestos. El peor comportamiento lo ha proporcionado, en la mayoría de los casos, el método de regresión vectorial (VR).

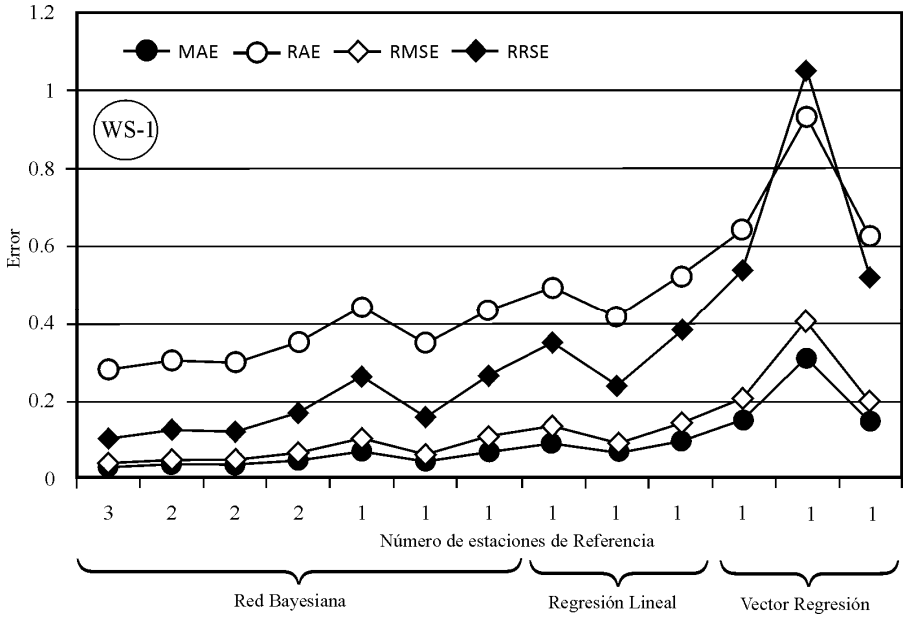

Figura 10.6:Errores obtenidos con los distintos modelos de la estación WS-1 en la etapa primera del proceso metodológico utilizado

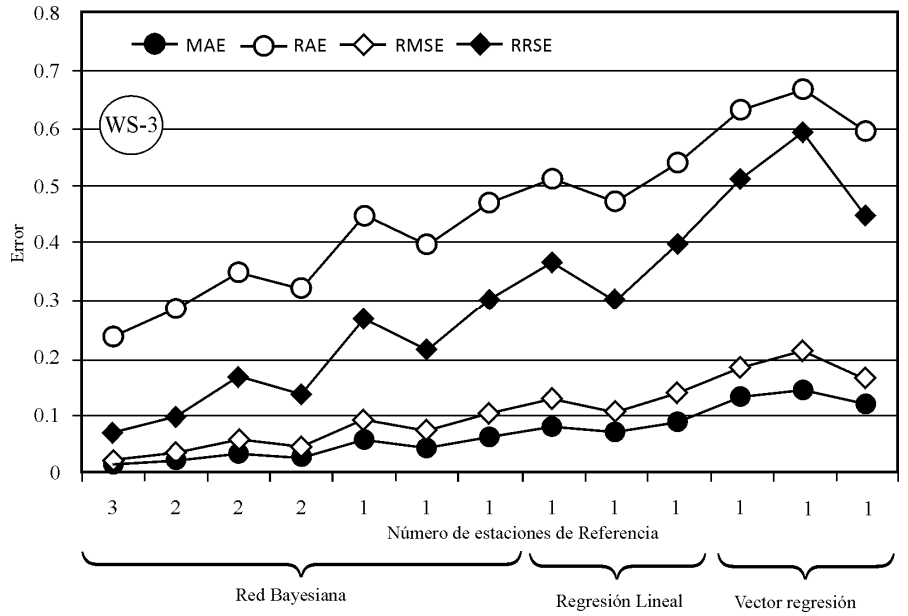

Figura 10.7:Errores obtenidos con los distintos modelos de la estación WS-2 en la etapa primera del proceso metodológico utilizado

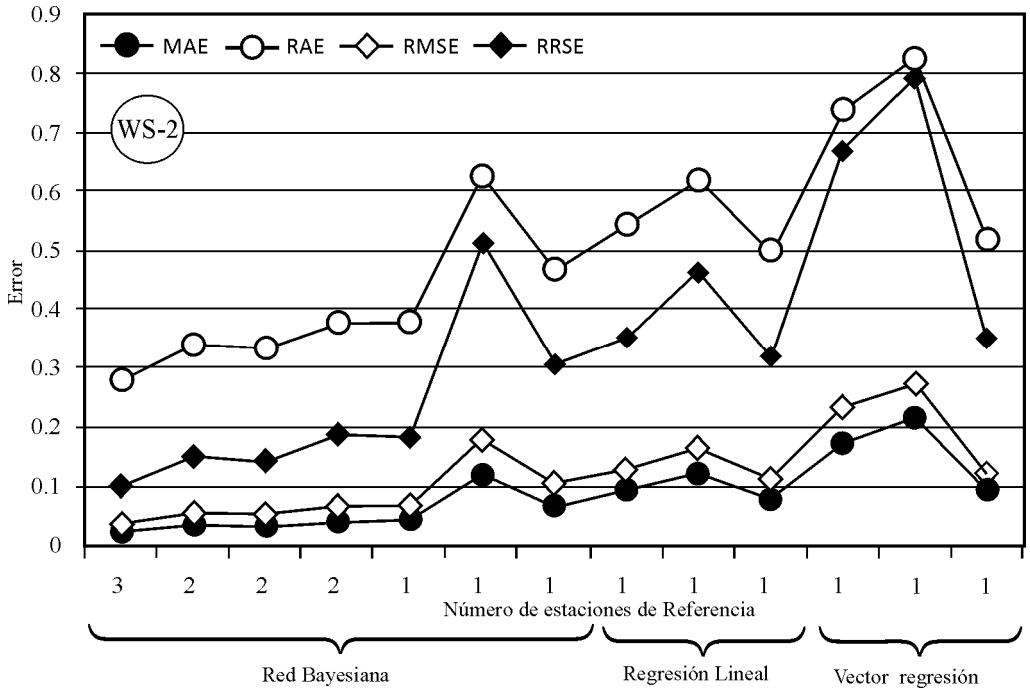

Figura 10.8:Errores obtenidos con los distintos modelos de la estación WS-3 en la etapa primera del proceso metodológico utilizado

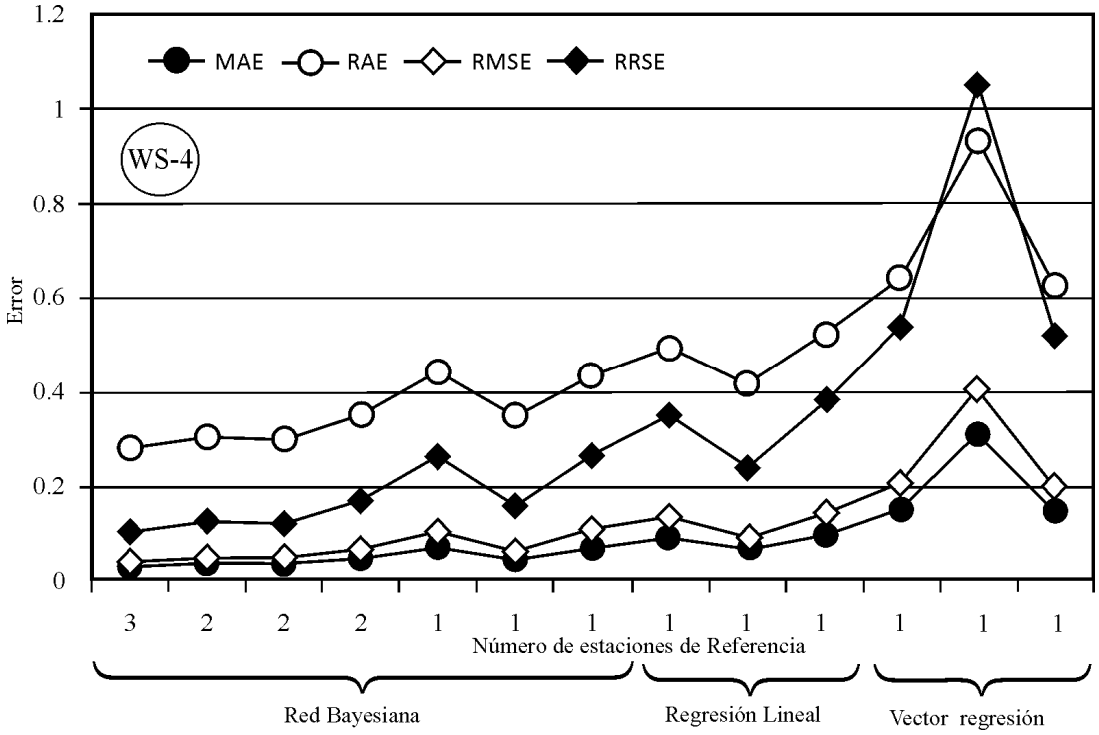

Figura 10.9:Errores obtenidos con los distintos modelos de la estación WS-4 en la etapa primera del proceso metodológico utilizado

De acuerdo con la segunda etapa de la metodología indicada en el apartado 5.2 se han seleccionado los modelos que en la primera etapa, según las figuras 10.6 a 10.9, han proporcionado menores errores en la estimación de los histogramas de frecuencia acumulada de la velocidad del viento. En la Tabla 10.2 se indican los modelos que han proporcionado mejor comportamiento en la primera etapa. Dado el reducido número de estaciones analizadas y los bajos y similares coeficientes de correlación existentes entre ellas (Tabla 10.1), no se puede extraer una clara conclusión sobre la influencia del coeficiente de correlación en los resultados obtenidos.

Tabla 10.2: :Modelos que han proporcionado mejor comportamiento en la primera etapa del proceso metodológico seguido

	Modelos				
	BN			LR	VR
Estación candidata	Número de estaciones de referencia				
	3	2	1	1	1
WS-1	WS-2;WS-3;WS-4	WS-2;WS-3	WS-2	WS-2	WS-4
WS-2	WS-1;WS-3;WS-4	WS-1;WS-3	WS-3	WS-1	WS-1
WS-3	WS-1;WS-2;WS-4	WS-1;WS-4	WS-4	WS-4	WS-2
WS-4	WS-1;WS-2;WS-3	WS-2;WS-3	WS-3	WS-3	WS-2

En las figuras 10.10 a 10.13 se muestran los grafos de los modelos de redes bayesianas que han proporcionado menores errores. Los grafos de dichas BNs representan el conocimiento cualitativo de los modelos. En los mismos se puede observar las relaciones de independencia/dependencia entre las variables que componen los modelos.

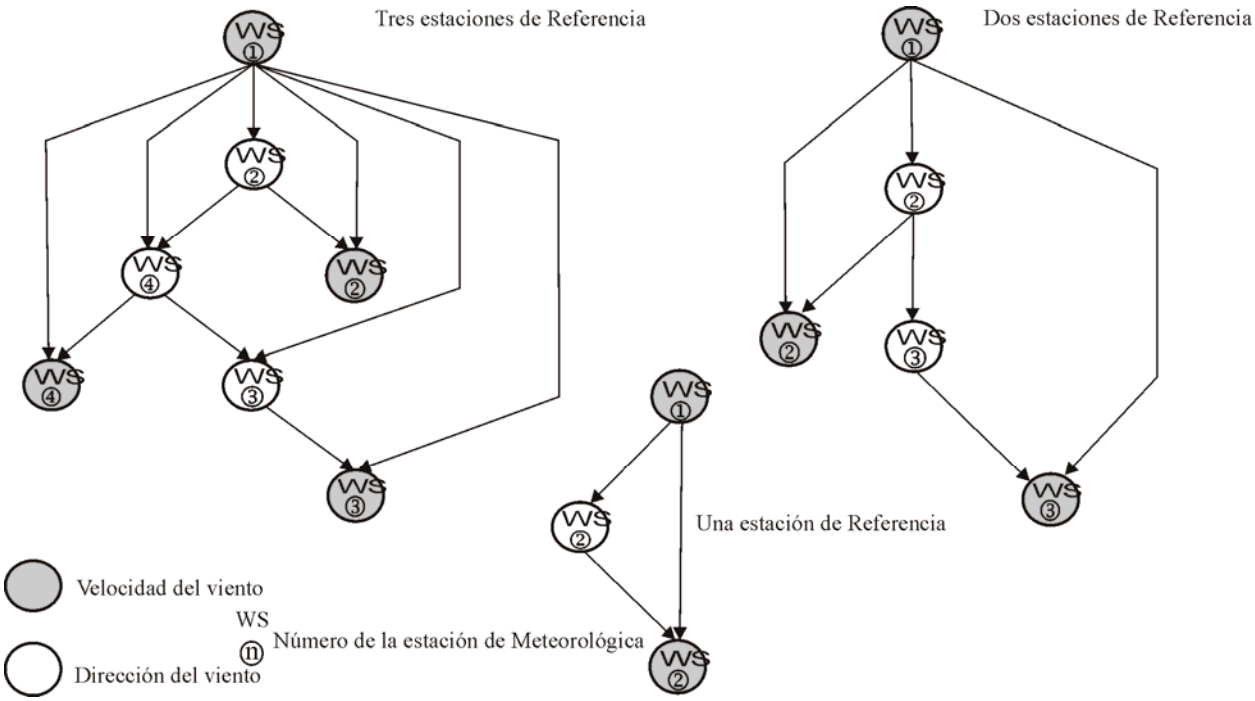

Figura 10.10:Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-1.

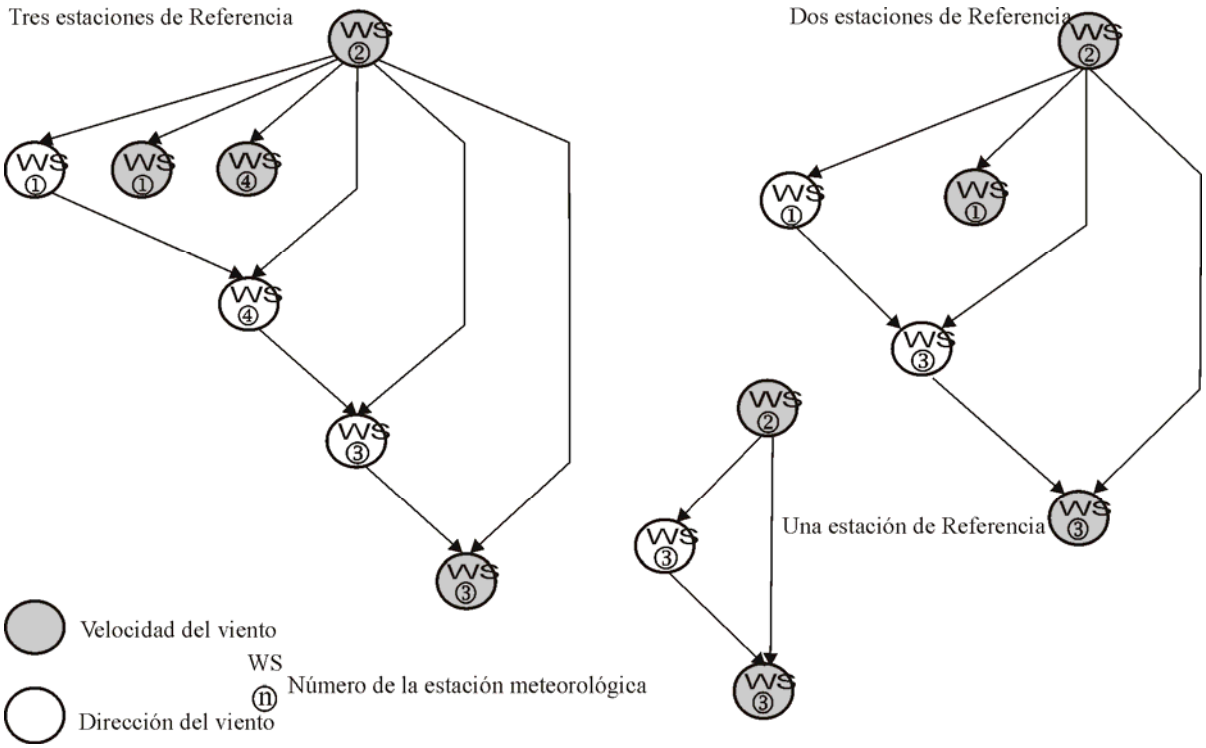

Figura 10.11:Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-2.

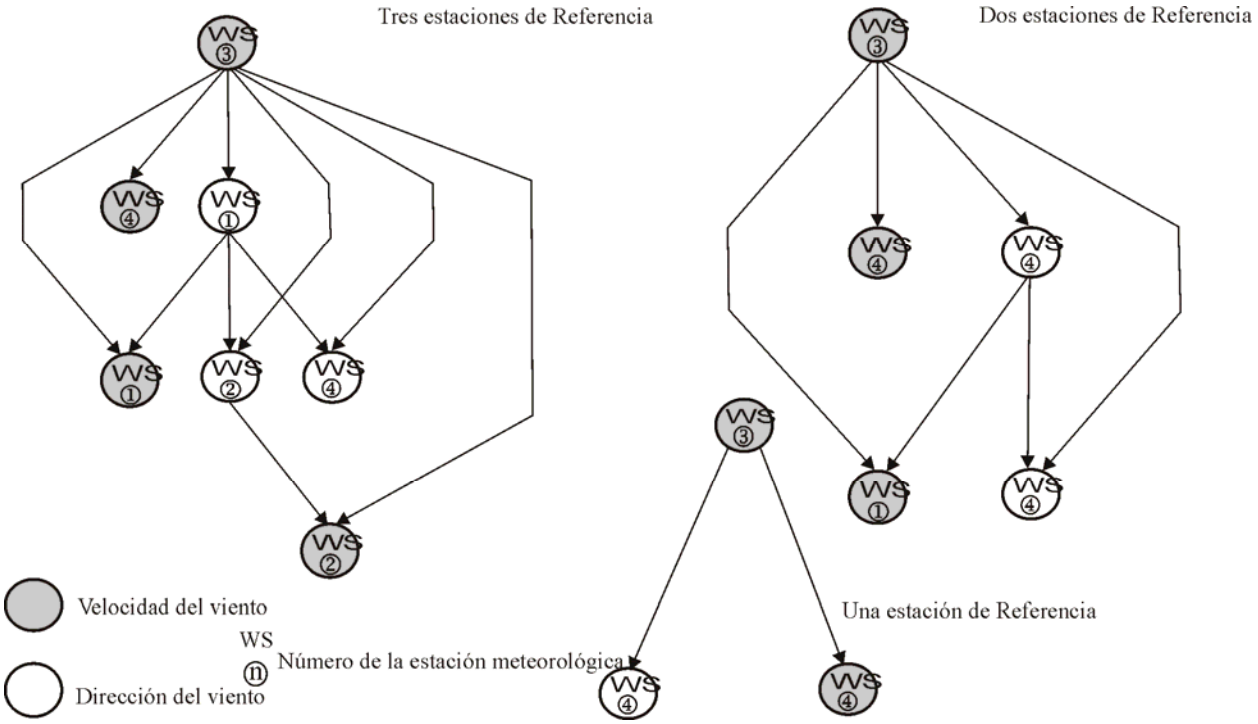

Figura 10.12:Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-3.

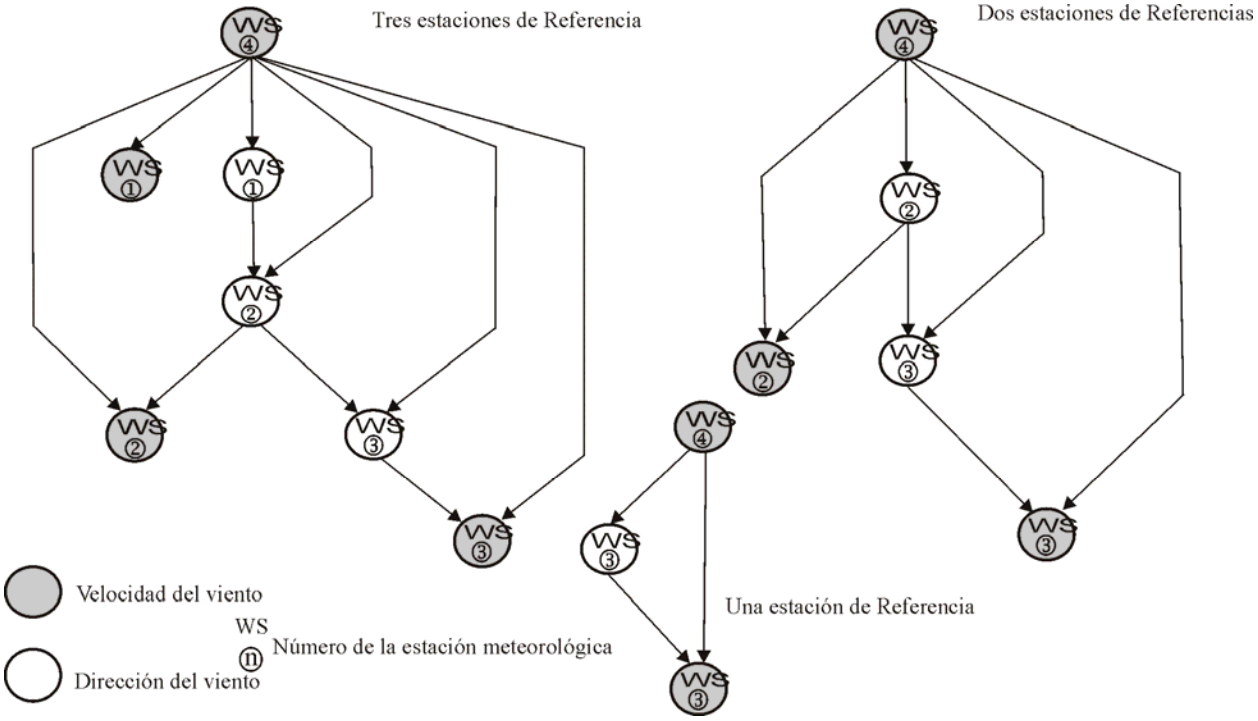

Figura 10.13:Grafos de los modelos de redes Bayesianas seleccionadas de la estación WS-4.

Con los modelos indicados en la Tabla 10.2 se han estimado los histogramas de frecuencia de la velocidad del viento a largo plazo de las cuatro estaciones y se han calculado los errores de dicha estimación. Con objeto de comparar los errores cometidos en la primera etapa con los originados en la segunda etapa, se ha representado en la Fig 10. 14 la métrica RMSE[7] de dichos errores en función de la métrica RMSE de los errores obtenidos en la primera etapa de evaluación de los modelos.

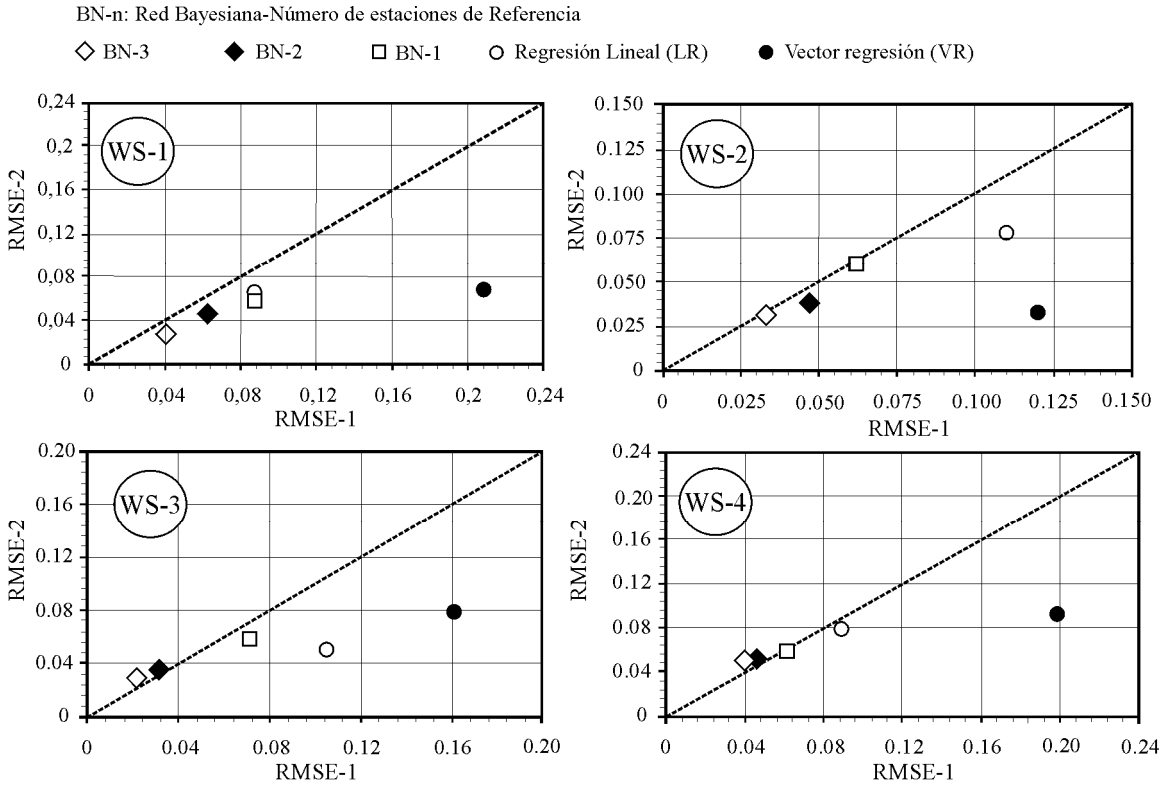

Figura 10.14:Métrica RMSE de los errores cometidos en la estimación de los histogramas de frecuencia de la velocidad del viento a largo plazo de las cuatro estaciones, en función de la métrica RMSE de los errores obtenidos en la primera etapa de evaluación de los modelos.

[7] Para simplificar la demostración se ha elegido la métrica RMSE. Las demás métricas proporcionaron un comportamiento similar.

Puede observarse en Fig 10.14 que los modelos obtenidos presentan un gran poder de generalización. Puede observarse que los errores obtenidos en la etapa 1 son muy parecidos a los errores cometidos en la predicción a largo plazo. Incluso, algunos modelos, fundamentalmente los modelos usados para comparación, presentan menores errores en la etapa de predicción que en la etapa 1. Puede comprobarse que los modelos de redes Bayesianas con tres y dos estaciones de referencia presentan, al igual que en la primera etapa (Fig. 10.6 a 10.9), los mejores ajustes a los histogramas de frecuencia acumulada del viento.

Tabla 10.3: Resumen de las métricas utilizadas para valorar de grado de predicción de la densidad de potencia media y la potencia eléctrica media extraíble del viento a largo plazo por las turbinas eólicas seleccionadas.

Métrica	Modelos	Estaciones anemométricas candidatas			
		WS-1	WS-2	WS-3	WS-4
	BN-3	0.741	0.881	0.963	0.866
	BN-2	0.584	0.834	0.888	0.843
M1	BN-1	0.542	1.045	0.635	0.777
	LR	0.635	0.714	0.797	0.831
	VR	0.337	0.715	0.514	0.464
	BN-3	0.663	0.982	0.942	0.954
	BN-2	0.465	0.939	0.88	0.931
M2	BN-1	0.408	1.192	0.639	0.861
	LR	0.489	0.805	0.81	0.919
	VR	0.208	0.763	0.503	0.496
	BN-3	0.708	0.966	0.952	0.93
	BN-2	0.533	0.921	0.887	0.908
M3	BN-1	0.484	1.162	0.645	0.839
	LR	0.57	0.789	0.813	0.895
	VR	0.282	0.755	0.514	0.494

En la Tabla 10.3 se muestran las métricas M1 a M3 definidas en el apartado 10.7. Valores de estas métricas iguales a 1 indicarían una correcta predicción. Puede observarse en la Tabla 10.3 que los modelos de redes Bayesianas con tres estaciones de referencia han presentado en todas las estaciones, con excepción de la WS-2, una mejor predicción de la densidad de potencia media del viento que los restantes modelos utilizados. Los modelos de redes Bayesianas con tres estaciones de referencia (BN-3) han presentado en todas las estaciones una mejor predicción de la potencia eléctrica media extraíble del viento con las dos turbinas eólicas seleccionadas que los restantes modelos utilizados. Asimismo, los modelos de redes Bayesianas con dos estaciones de referencia (BN-2) han presentado en todas las estaciones, con excepción de la WS-1[8], una mejor predicción de la potencia eléctrica media extraíble del viento con las dos turbinas eólicas seleccionadas que los restantes modelos utilizados.

10.9 Conclusiones

Se ha presentado en este estudio una aplicación de las redes probabilísticas Bayesianas a la estimación de los histogramas de frecuencia de la velocidad del viento a largo plazo de estaciones con cortas medidas de datos de viento. Los modelos de redes Bayesianas propuestos permiten utilizar múltiples estaciones de referencia con una larga historia de medidas de la velocidad y dirección del viento. Es decir, pueden involucrar información regional del recurso eólico. Este método, al utilizar una representación gráfica de los modelos, constituye una herramienta atractiva para la especificación del conocimiento cualitativo de los mismos. Los grafos de las Redes Bayesianas expresan las relaciones de dependencia/independencia entre las variables que componen los modelos. El método propuesto supone una alternativa a los modelos MCP que emplean regresiones lineales para relacionar las velocidades del viento entre una estación candidata y una estación de referencia. Como resultado de la aplicación del modelo de red bayesiana propuesto en este estudio, a los datos de velocidad y dirección del viento registrado en las cuatro estaciones meteorológicas del archipiélago canario, las conclusiones obtenidas son las siguientes: En las cuatro estaciones analizadas los modelos de BNs con tres (BN-3) y dos (BN-2) estaciones de referencia han proporcionado menores errores que los MCP de referencia utilizados. Independientemente de la métrica utilizada en la estimación de los histogramas de frecuencia acumulada del viento a

[8] Como puede comprobarse en la Fig. 10.3 la velocidad del viento en la WS-1 es muy baja. Presenta bajas frecuencias del viento por encima de la velocidad de arranque de las turbinas eólicas seleccionadas.

largo plazo.

Los modelos de BN-3 y BN-2 obtenidos presentan un gran poder de generalización. Los errores obtenidos en la etapa de entrenamiento son muy parecidos a los errores cometidos en la predicción a largo plazo.

Los modelos de redes Bayesianas con tres estaciones de referencia (BN-3) han presentado en todas las estaciones, una mejor predicción de la potencia eléctrica media extraíble del viento con las dos turbinas eólicas seleccionadas, que los restantes modelos utilizados.

CAPITULO 11

Un nuevo método probabilístico para la estimación de las características de la velocidad del viento a largo plazo en un sitio candidato

11 UN NUEVO MÉTODO PROBABILÍSTICO PARA LA ESTIMACIÓN DE LAS CARACTERÍSTICAS DE LA VELOCIDAD DEL VIENTO A LARGO PLAZO EN UN SITIO CANDIDATO. 247
11.1 Introducción. 247
11.2 Métodos utilizados en la comparación....248
11.2.1 *Joint Probabilistic Approach* (*JPA*) 248
11.2.2 El Weibull Scale Method (WSM). 249
11.2.3 El Variance Ratio Method (VRM) 250
11.3 Método propuesto....251
11.3.1 Estimación de la Distribución Marginal utilizada. 253
11.4 Datos meteorológicos utilizados 254
11.5 Metodología 258
11.6 Características del viento analizadas. 260
11.6.1 Velocidad del viento 260
11.6.2 Densidad de la potencia eólica 261
11.6.3 Potencia Eléctrica 261
11.7 Métricas utilizadas en la evaluación 263
11.8 Análisis de los resultados 263
11.9 Conclusiones 277

11 UN NUEVO MÉTODO PROBABILÍSTICO PARA LA ESTIMACIÓN DE LAS CARACTERÍSTICAS DE LA VELOCIDAD DEL VIENTO A LARGO PLAZO EN UN SITIO CANDIDATO.

11.1 Introducción.

Como consecuencia de la variabilidad interanual del viento, a la hora de estimar el potencial eólico de un emplazamiento, hay que tener en cuenta las características del viento a largo plazo (varios años) [6,18,32,171]. Sin embargo, en muchos lugares solo se dispone de datos de viento medidos durante un corto periodo de tiempo (generalmente un año). Para solventar este inconveniente, en la literatura científica se han propuesto diversos métodos para estimar las características de la velocidad del viento a largo plazo en dichos sitios [9,10,15,16,18,20,21,32,162,163,170,171,173,182].

Los mencionados métodos utilizan medidas simultáneas de la velocidad del viento en el sitio en cuestión y en uno [9,10,15,16,18,20,32,163,171] o varios [21,162,170,173] sitios cercanos de referencia con una larga historia de medidas de datos de viento. Los métodos que han sido propuestos utilizan distintos tipos de funciones para relacionar las velocidades del viento del conjunto de largo plazo con los datos del conjunto de corto plazo. Frecuentemente, el tipo de relación es de tipo lineal [9,15], sin embargo, también han sido propuestas relaciones probabilísticas [9-10,14].

En este capítulo se propone un nuevo método probabilístico de Measure-Correlate-Predict (MCP) para estimar las características de la velocidad del viento a largo plazo (long-term) en un emplazamiento candidato. El método que se propone utiliza la función de densidad de probabilidad de la velocidad del viento en el sitio candidato condicionada a la velocidad del viento en el sitio de referencia. Para ello se han utilizado distribuciones bivariables del tipo contingencia (en su traducción al inglés, Contingency-type bivariate distributions) con distribuciones marginales especificadas [140-141]. Los datos eólicos utilizado son los recopilados en seis estaciones meteorológicas ubicada en el Archipiélago Canario (España).

Con objeto de evaluar la capacidad del modelo para representar las características del viento a largo plazo se llevan a cabo tres análisis: a) Un análisis del grado de ajuste de la función de distribución de frecuencias acumulada para la velocidad del viento al histograma de frecuencias relativas de la velocidad media horaria registrada en seis estaciones meteorológicas situadas en el archipiélago canario; b) Un análisis del grado de ajuste de la función de distribución de frecuencias acumulada de la densidad de potencia eólica al histograma de frecuencias relativas

del cubo de la velocidad media horaria registrada en las estaciones mencionadas ; c) Un análisis del grado de ajuste de la función de distribución de frecuencias acumulada de la potencia eléctrica al histograma de frecuencias relativas del la potranca eléctrica generada por un aerogenerador. Para este último análisis se ha utilizado un aerogenerador comercial de 900 kW con regulación de paso variable [165]

En los tres análisis mencionados se han utilizados dos métricas. Dichas métricas son: El coeficiente de determinación, R^2 y la raíz cuadrada del cuadrado del error relativo (RRSE, siglas de la terminología en inglés, Root Relative Square Error). Además, en el análisis del modelo propuesto se ha llevado a cabo una comparación de las métricas antes señaladas con las obtenidas con otros modelos probabilísticos y lineales referenciados en la literatura científica [9-10,16]. Entre los modelos lineales se ha escogido el Variance Ratio Method (VRM), ya que de acuerdo con las conclusiones de la referencia [9], “de los cuatro MCPs comparados en la misma, sólo el VRM parece dar resultados consistentes durante el proceso de estimación, para todas las métricas analizadas”.

11.2 Métodos utilizados en la comparación

El método, Joint Probabilistic Approach (JPA) [16], Weibull Scale Method [10] y el Variance Ratio method [9], han sido elegidos para comparar sus resultados con el método alternativo propuesto por los autores.

11.2.1 *Joint Probabilistic Approach* (*JPA*)

El procedimiento usado por García-Rojo [16] se basa en el cálculo de la función de densidad de probabilidad $p_{c-r}^{ST}(v_c, d_c, v_r, d_r)$ de la velocidad (*v*) y dirección (*d*) del viento a corto plazo (*ST*) del sitio candidato (*c*) y del sitio de referencia (*r*).

A partir de la función de densidad de probabilidad (JPMF, de la terminología en inglés Joint Probabilistic Mass Function) a corto plazo y de la función de densidad de probabilidad de la velocidad y dirección del viento a largo plazo en el sitio de referencia, $p_r^{LT}(v,d)$, se estima la función de densidad de probabilidad de la velocidad y dirección del viento a largo plazo (*LT*) en el sitio candidato, $p_c^{LT}(v,d)$ (Ec 11-1).

(Ec 11-1) $$p_c^{LT}(v_i, d_j) = \frac{1}{NF} \sum_{k=1}^{Nw} \sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)$$

Donde *NF* es un factor de normalización[1], (Ec 11-2)

(Ec 11-2) $$NF = \sum_{i=1}^{Nw} \sum_{j=1}^{Nd} \sum_{k=1}^{Nw} \sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)$$

Nw y *Nd* son los números de bines de velocidad y dirección del viento de la joint probability mass function. En este trabajo se han considerado doce bines de dirección de 30º para definir la dirección del viento en el sitio candidato y en el de referencia. El tamaño de los bines de velocidad ha sido de 1 m/s. Para la implementación del método se ha utilizado el Mathcad Software 2001*i* programa de MathSoft Engineering & Education, Inc [142]. En la programación de la JPMF a corto plazo se utilizó la aplicación que presenta dicho software para crear matrices anidadas (nested). Es decir matrices cuyos elementos son también matrices.

La función de densidad de probabilidad marginal para los *Nw* bines puede obtenerse a partir de la (Ec 11-1),

(Ec 11-3) $$p_c^{LT}(v_i) = \frac{1}{NF} \sum_{j=1}^{Nd} \sum_{k=1}^{Nw} \sum_{z=1}^{Nd} p_{c-r}^{ST}\left(v_i, d_j, v_k, d_z\right) p_r^{LT}(v_k, d_z)\,; \qquad i = 1 \ldots Nw$$

11.2.2 El Weibull Scale Method (WSM).

Este método empírico parte de la hipótesis de que las velocidades del viento en el sitio de referencia y en el candidato siguen una distribución de Weibull de dos parámetros, cuya función de densidad de probabilidad (pdf, del inglés probability density function), W-pdf [72], viene dada por (Ec 11-4)

(Ec 11-4) $$f(v;\alpha,\beta) = \frac{\alpha}{\beta}\left(\frac{v}{\beta}\right)^{\alpha-1} \exp\left[-\left(\frac{v}{\beta}\right)^{\alpha}\right]$$

[1] En la referencia [9] no se incluye dicho factor. Probablemente, debido a una errata.

Además, se considera la existencia de una relación lineal entre los parámetros de escala (β) por un lado, y de los de forma (α) por otro, de las pdfs del sitio candidato y del de referencia, (Ec 11-5)

$$\text{(Ec 11-5)} \quad \frac{\lambda_c^{ST}}{\lambda_r^{ST}} = \frac{\lambda_c^{LT}}{\lambda_r^{LT}} \quad \Rightarrow \quad \lambda_c^{LT} = \frac{\lambda_c^{ST}}{\lambda_r^{ST}} \lambda_r^{LT};$$

En la (Ec 11-5), λ representa al parámetro de escala o de forma que se esté considerando.
Los parámetros de la distribución de Weibull fueron estimados mediante el método de los mínimos cuadrados [54]. Para la implementación de este método se utilizó el programa Mathcad 2001*i* de MathSoft Engineering & Education, Inc [142].

11.2.3 El Variance Ratio Method (VRM)

El Variance Ratio Method, propuesto por Rogers et al. [9], predice la velocidad del viento a largo plazo del sitio candidato v_c^{LT}, mediante la relación lineal dada por la (Ec 11-6)

$$\text{(Ec 11-6)} \quad v_c^{LT} = \left[\overline{v}_c^{ST} - \left(\frac{s_c^{ST}}{s_r^{ST}} \right) \overline{v}_r^{ST} \right] + \left(\frac{s_c^{ST}}{s_r^{ST}} \right) v_r^{LT}$$

Donde $\overline{v}_r^{ST}$, $\overline{v}_c^{ST}$, s_r^{ST} y s_c^{ST} son las medias y las desviaciones estándar a corto plazo de los datos de viento de la estación de referencia y de la candidata. Dichos parámetros han sido calculados para doce bines de dirección de tamaño 30º. Estos se han definido para la dirección del viento en el sitio de referencia. v_r^{LT} representa a las velocidades de viento observadas a largo plazo en el sitio de referencia. Si la (Ec 11-6) proporciona valores negativos de la velocidad, entonces se le asigna a dichas velocidades el valor nulo. Para la implementación de este método se utilizó el programa Mathcad 2001*i* de MathSoft Engineering & Education, Inc [142].

11.3 Método propuesto

Sean V_c^{ST} y V_r^{ST} dos variables aleatorias que representan la velocidad del viento a corto plazo en el sitio de candidato y en el de referencia, respectivamente. Si existe y se conoce la función de densidad conjunta de probabilidad $f_{cr}^{ST}(v_c, v_r)$, la función de densidad de probabilidad condicional de la variable aleatoria V_c^{ST}, representada por $f_c^{ST}(v_c|v_r)$, para un valor v_r de V_r^{ST}, viene definida por (Ec 11-7) [143].

(Ec 11-7) $$f_c^{ST}(v_c|v_r) = f_{c-r}^{ST}(v_c, v_r) / f_r^{ST}(v_r)$$

Donde $f_r^{ST}(v_r)$ es la función de densidad de probabilidad de V_r^{ST} de manera tal que $f_r^{ST}(v_r) > 0$.

En el método propuesto, a partir de la función de densidad de probabilidad condicional a corto plazo, (Ec 11-7), y de la función de densidad de probabilidad a largo plazo en el sitio de referencia, $f_r^{LT}(v)$, se estima la función de densidad de probabilidad a largo plazo en el sitio candidato, $f_c^{LT}(v)$, (Ec 11-8).

(Ec 11-8) $$f_c^{LT}(v_c) = \frac{1}{CNF} \int_0^{\infty} f_c^{ST}(v_c|v_r)\, f_r^{LT}(v_r)\, dv_r$$

Donde CNF es un factor de normalización, (Ec 11-9)

(Ec 11-9) $$CNF = \int_0^{\infty}\int_0^{\infty} f_c^{ST}(v_c|v_r)\, f_r^{LT}(v_r)\, dv_r\, dv_c$$

Existen diferentes métodos para la construcción de distribuciones bivariables a partir de la forma de distribuciones marginales. En el estudio que se realiza en el presente capítulo se han utilizado la familia de distribuciones propuestas por Plackett [140-141], las cuales se denominan distribuciones tipo c (del inglés, contingency-type o simplemente c-type).

Por tanto la (Ec 11-7) puede escribirse como se indica en (Ec 11-10)

(Ec 11-10) $$f_c^{ST}(v_c|v_r) = \frac{1}{2\sqrt{S2}} f_c^{ST}(v_c)\left\{\frac{(\psi-1)\left[S1-2\psi F_c^{ST}(v_c)\right]\left[S1-2\psi F_r^{ST}(v_r)\right]}{S2}+\psi+1\right\}$$

Donde, S1 viene dado por (Ec 11-11) y S2 por (Ec 11-12).

(Ec 11-11) $$S1 = 1+\left[F_c^{ST}(v_c)+F_r^{ST}(v_r)\right](\psi-1)$$

(Ec 11-12) $$S2 = S1^2 - 4\psi(\psi-1)F_c^{ST}(v_c)F_r^{ST}(v_r)$$

En las ecuaciones anteriores, $F_c^{ST}(v_c)$ y $F_r^{ST}(v_r)$ son las distribuciones de frecuencia acumulada (cdf). $f_c^{ST}(v_c)$**,** es la función de densidad de probabilidad (pdf) en el sitio candidato. ψ , es el coeficiente de asociación. Éste debe ser estimado[2]. En este estudio para estimar ψ igualamos el coeficiente de correlación de la muestra de datos de las estaciones candidata y de referencia al coeficiente de correlación del modelo [140-141].

El coeficiente de correlación del modelo a corto plazo, ζ^{ST} , viene dado por (Ec 11-13).

(Ec 11-13) $$\xi^{ST} = \frac{E(v_c,v_r)-E(v_c)E(v_r)}{\sigma_c\sigma_r}$$

Donde los valores estimados, *E*, vienen dados por la (Ec 11-14) y las varianzas σ_c^2 y σ_r^2 por la (Ec 11-15).

(Ec 11-14) $$E(v_c v_r) = \int_0^\infty\int_0^\infty v_c v_r f_{cr}^{ST}(v_c,v_r)dv_c dv_r \;;\; E(v_c) = \int_0^\infty v_c f_c^{ST}(v_c)dv_c \;;$$

$$E(v_r) = \int_0^\infty v_r f_r^{ST}(v_r)dv_r$$

(Ec 11-15) $$\sigma_c^2 = \int_0^\infty \left(v_c - E(v_c)\right)^2 f_c^{ST}(v_c)dv_c \;;\; \sigma_r^2 = \int_0^\infty \left(v_r - E(v_v)\right)^2 f_r^{ST}(v_r)dv_r$$

[2] Esta distribución bivariable tiene un solo parámetro, además de los marginales.

El coeficiente de correlación de la muestra, $\hat{r}$ puede calcularse a partir de los n-valores de la muestra ($v_{c,i}, v_{r,i}$), según la (Ec 11-16).

$$\text{(Ec 11-16)} \quad \hat{r} = \frac{n\sum_{i=1}^{n} v_{c,i} v_{r,i} - \left(\sum_{i=1}^{n} v_{c,i}\right)\left(\sum_{i=1}^{n} v_{r,i}\right)}{\left[n\sum_{i=1}^{n} v_{c,i}^2 - \left(\sum_{i=1}^{n} v_{c,i}\right)^2\right]^{\frac{1}{2}}\left[n\sum_{i=1}^{n} v_{r,i}^2 - \left(\sum_{i=1}^{n} v_{r,i}\right)^2\right]^{\frac{1}{2}}}$$

La (Ec 11-15) se iguala a (Ec 11-16) y el método de Secant/Mueller [144] se utiliza para calcular[3] ψ.

11.3.1 Estimación de la Distribución Marginal utilizada.

En la literatura científica han sido propuestas diversas pdfs para representar los regímenes de viento de un lugar [54]. Entre dicho abanico de posibilidades pueden seleccionarse las más apropiadas para constituir $f_c^{ST}(v)$ y $f_r^{ST}(v)$. Teniendo en cuenta que para series de datos eólicos de emplazamientos en el archipiélago canario, la función de densidad que mejor ajusta los datos es la función de densidad de probabilidad de Weibull Mixta de dos parámetros (WW-pdf) [54,183-184].

La WW-pdf, depende de 5 parámetros ($\alpha_1, \beta_1, \alpha_2, \beta_2 > 0; 0 \le \omega \le 1$) y viene dado por la Ec 11-17.

$$\text{(Ec 11-17)} \quad f(v;\alpha_1,\beta_1,\alpha_2,\beta_2,\omega) = \omega\left\{\frac{\alpha_1}{\beta_1}\left(\frac{v}{\beta_1}\right)^{\alpha_1-1}\exp\left[-\left(\frac{v}{\beta_1}\right)^{\alpha_1}\right]\right\} + (1-\omega)\left\{\frac{\alpha_2}{\beta_2}\left(\frac{v}{\beta_2}\right)^{\alpha_2-1}\exp\left[-\left(\frac{v}{\beta_2}\right)^{\alpha_2}\right]\right\}$$

[3] Primero se utiliza el método de la Secante. Si este falla para calcular la raíz de ψ, estonces se aplica el método de Mueller que es una modificación del primero. Este algoritmo ha sido implementado en el programa Mathcad® 2001i , programa de MathSoft Engineering & Education, Inc [18], el cual ha sido utilizado en este artículo.

La función de distribución acumulada (WW-cdf) se puede expresar según la (Ec 11-18).

(Ec 11-18) $$F(v;\alpha_1,\beta_1,\alpha_2,\beta_2,\omega)=\omega\left\{1-\exp\left[-(\frac{v}{\beta_1})^{\alpha_1}\right]\right\}+(1-\omega)\left\{1-exp\left[-(\frac{v}{\beta_2})^{\alpha_2}\right]\right\}$$

Donde, β_1 y β_2 son los parámetros de escala, que posee igual unidades que la variable aleatoria. α_1 y α_2 son los parámetros de forma.

El error cuadrático mínimo ha sido utilizado para estimar los cinco parámetros de los cuales depende la WW-pdf. El algoritmo de Levenberg-Marquardt [77] ha sido empleado para resolver el problema[4].

11.4 Datos meteorológicos utilizados

Los datos meteorológicos utilizados (medias horarias de velocidad y dirección del viento del periodo 1999-2008) son los correspondientes a seis estaciones meteorológicas instaladas en seis islas del archipiélago Canario (España) (Fig 11-1). La información ha sido suministrada por la Agencia estatal de Meteorología (AEMET) del Ministerio de Medio Ambiente y Medio Rural y Marino del Gobierno de España. Dichas estaciones meteorológicas están ubicadas en los aeropuertos públicos del Archipiélago Canario y AEMET expide certificaciones sobre la información meteorológica que consta en los archivos relativa al tiempo atmosférico pasado registrado en las mismas.

[4] El software Mathcad® Software 2001*i* de MathSoft Engineering & Education, Inc [18] es el que se emplea para calcular los valores de los cinco parámetros.

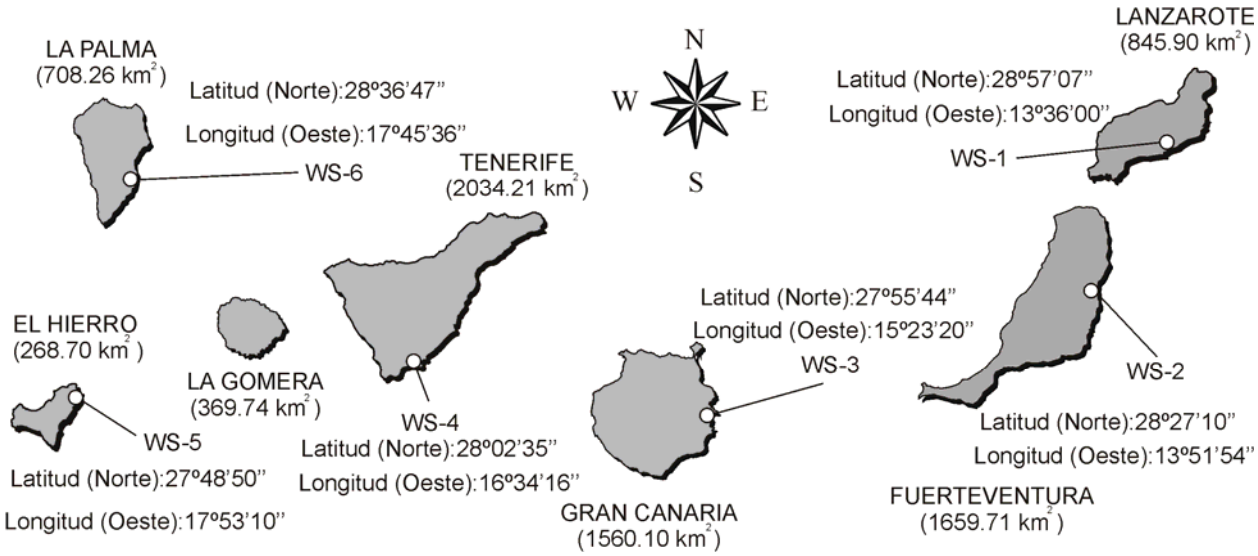

Figura 11.1:Ubicación de la estaciones meteorológicas utilizadas

La altura de las estaciones es de 10 metros sobre el nivel del terreno. La Fig 11-2 muestra, para el año 2008, el histograma de frecuencias relativas de la velocidad del viento para cada una de las estaciones con bines de tamaño 1 m s^{-1}. Cada histograma muestra además la WW-pdf y la W-pdf.

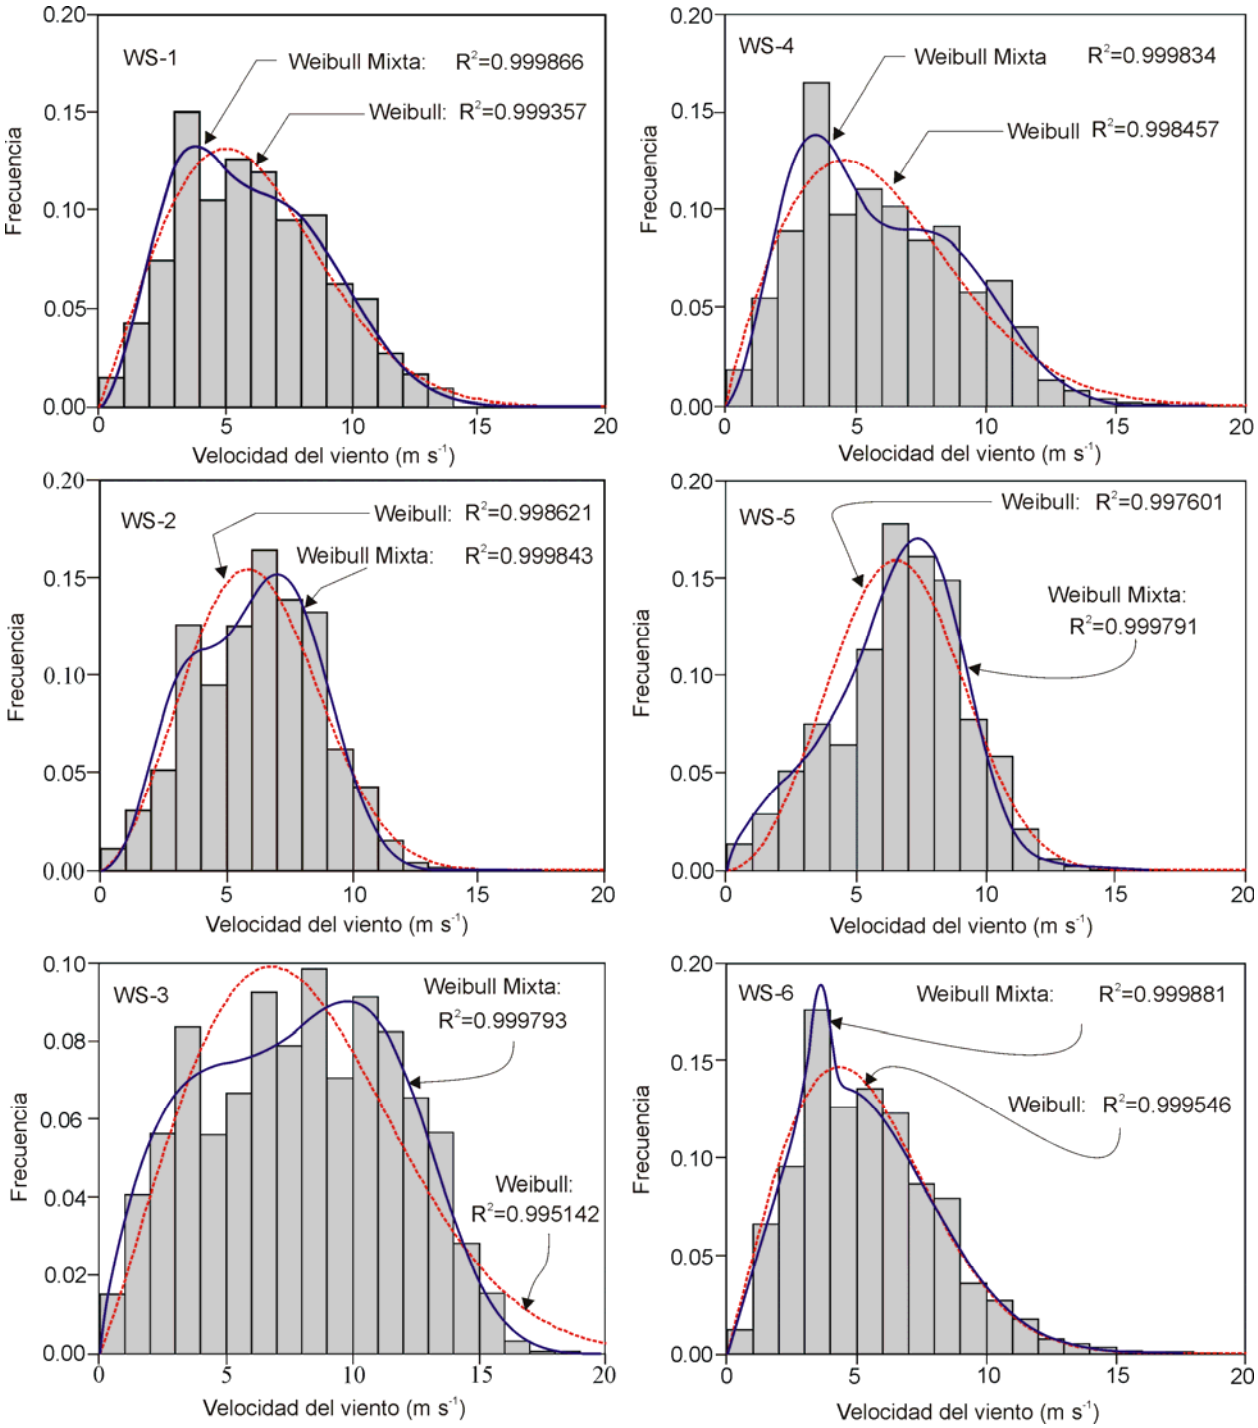

Figura 11.2: Histogramas de las frecuencias relativas de la velocidad del viento del año 2008 para las seis estaciones utilizadas. Cada histograma muestra además el ajuste mediante la Weibull Mixta-pdf y Weibull-pdf.

En la Tabla 11.1 se exponen datos, como la media, la desviación estándar, los coeficientes de variación, curtosis y asimetría de la velocidad del viento en el año 2008 y en el periodo 1999-2008, de todas las estaciones analizadas

Tabla 11.1 : Medias, desviación estándar (S.D.), curtosis y asimetría de la velocidad del viento recopilada en los diferentes anemómetros de las estaciones meteorológicas.

	Año 2008						**Años 1999-2008**					
	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
Media ($m\ s^{-1}$)	6.12	6.23	7.98	6.01	6.66	5.47	5.83	5.83	7.14	5.64	5.97	4.82
S.D ($m\ s^{-1}$)	2.91	2.46	3.79	3.08	2.50	2.74	3.02	2.53	3.73	3.17	2.89	2.32
curt	-0.37	-0.40	-0.92	-0.45	-0.21	0.96	-0.13	-0.39	-0.86	-0.15	0.46	1.02
Asimetría	0.39	-0.01	-0.02	0.42	-0.29	0.80	0.38	0.12	0.06	0.57	0.21	0.69

Por otro lado, la Tabla 11.2 muestra los coeficientes de correlación entre las velocidades del viento de las diferentes estaciones. Dichos resultados se muestran tanto para el año 2008 como para el periodo 1999-2008.

Respecto de la longitud de datos disponible en este estudio hay que señalar que, según Hiester and Pennell [6], es posible estimar con cierta precisión los valores medios del comportamiento del viento en un sitio a partir de 10 años de datos en el sitio candidato. Sin embargo, otros autores [185-186] asumen que se necesitan veinte o treinta años para caracterizar a largo plazo un recurso eólico.

Tabla 11.2 Coeficientes de correlación lineal entre los datos la velocidad del viento de las diferentes estaciones meteorológicas.

	Año 2008						**Años 1999-2008**					
	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
WS-1	1.000	0.660	0.736	0.497	0.410	0.509	1.000	0.649	0.663	0.489	0.430	0.485
WS-2	0.660	1.000	0.671	0.491	0.488	0.501	0.649	1.000	0.674	0.514	0.456	0.521
WS-3	0.736	0.671	1.000	0.502	0.472	0.552	0.663	0.674	1.000	0.492	0.469	0.566
WS-4	0.497	0.491	0.502	1.000	0.248	0.319	0.489	0.514	0.492	1.000	0.259	0.377
WS-5	0.410	0.488	0.472	0.248	1.000	0.449	0.430	0.456	0.469	0.259	1.000	0.480
WS-6	0.509	0.501	0.552	0.319	0.449	1.000	0.485	0.521	0.566	0.377	0.480	1.000

11.5 *Metodología*

La Figuras 11.3 muestra un esquema del procedimiento empleado. En éste se observa que hay un sitio candidato del cual se dispone datos eólicos (velocidades medias horarias) para un periodo corto (2008) y una estación de referencia para la cual se dispone de información eólica (medias horarias de la velocidad del viento) para un periodo largo de tiempo (en este caso, 10 años:1999-2008). Usando el modelo descrito en figura 11.3 el objetivo es estimar las características de la velocidad del viento en la estación candidata para el largo plazo. Para ello el modelo ha de ser entrenado y testeado con la serie de datos conocido del año 2008 (Esta fase se indica mediante el círculo número 1 de la Fig 11.3).

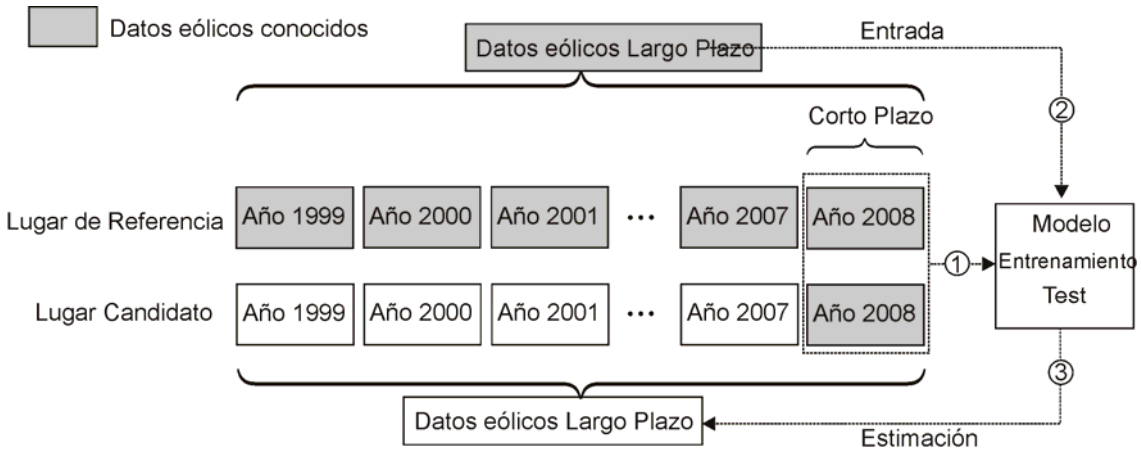

Figura 11.3: Esquema de la metodología utilizada para aprender y evaluar con el modelo propuesto

Para entrenar y ensayar el modelo se ha utilizado el método de validación cruzada estratificada con *k* particiones [187-188]. El método se basa en dividir aleatoriamente el conjunto de datos disponibles en *k* subconjuntos disjuntos de similar tamaño. Se entrena el modelo con el conjunto de datos formado por la unión de *k*-1 subconjuntos y se utiliza el subconjunto restante para el ensayo. Este procedimiento se repite *k* veces, utilizando cada vez un subconjunto diferente para ensayar y determinar un error parcial δ_i. El error global $\overline{\delta}$ se calcula como la media aritmética de los *k* errores, (Ec 11-19). [170]

(Ec 11-19) $$\overline{\delta} = \frac{1}{k}\sum_{i=1}^{k}\delta_i$$

La desviación estándar $S_{\overline{\delta}}$ de los errores vendrá dada por (Ec 11-20)

(Ec 11-20) $$S_{\overline{\delta}} = \sqrt{\frac{1}{k-1}\sum_{i=1}^{k}\left(\delta_i - \overline{\delta}\right)^2}$$

Si se considera la hipótesis de que los errores son independientes y se distribuyen según una ley normal, puede estimarse el intervalo de confianza del error mediante el test de t-Student test. Es decir, aplicando el estadístico indicado en (Ec 11-21)

(Ec 11-21) $$\frac{\bar{\delta}-\mu}{S_{\bar{\delta}}/\sqrt{k}} \sim t_{k-1}$$

Este estadístico tiene una distribución *t* con *k*-1 grados de libertad. Por tanto, el intervalo de confianza para el error medio μ vendrá dado por (Ec 11-22). Donde α es el nivel de significación.

(Ec 11-22) $$P\left\{\bar{\delta}-t_{\alpha/2,k-1}\sqrt{\frac{1}{k(k-1)}\sum_{i=1}^{k}(\delta_i-\bar{\delta})^2} < \mu < \bar{\delta}+t_{\alpha/2,k-1}\sqrt{\frac{1}{k(k-1)}\sum_{i=1}^{k}(\delta_i-\bar{\delta})^2}\right\}=1-\alpha$$

En este trabajo se ha utilizado el criterio estándar de tomar *k*=10 [187-188] y α=0.05 (95% de confianza).

Hay que señalar que el intervalo de confianza de la variabilidad del error obtenido al estimar la función de densidad de probabilidad de la potencia eléctrica no tiene en cuenta la incertidumbre de la producción de la turbina eólica.

Los datos eólicos a largo plazo conocidos en la estación de referencia alimentarán al modelo (fase indicada mediante el círculo nº 2 de la figura 11.3) para estimar los datos a largo plazo en la estación candidata.

Utilizando tanto el método propuesto como los escogidos para la comparación, se estiman los datos eólicos a largo plazo de las seis estaciones candidatas. Posteriormente se comparan los valores estimados para la estación candidata con los realmente observados. Las características del viento analizadas en esta comparación se muestran en el apartado 11.6 y las métricas utilizadas en la evaluación se indican en el 11.7.

11.6 *Características del viento analizadas.*

Las características analizadas son las distribuciones estadísticas de la velocidad del viento, de la densidad de potencia eólica y de la potencia eléctrica generada por una turbina eólica a largo plazo en el sitio candidato.

11.6.1 Velocidad del viento

En el caso del método propuesto y del WSM se analizarán las funciones de densidad de

probabilidad de la velocidad del viento para el modelo propuesto, (Ec 11-8), y para el WSM la (Ec 11-4), con los parámetros estimados según la (Ec 11-5).

En el caso del JPA se analizará la función de masa de probabilidad de la velocidad, (Ec 11- 3).

Del VRM se analizará el histograma de frecuencias (*Nw* bins de ancho 1 m/s) que se confeccione a partir de los datos estimados por el mismo.

11.6.2 Densidad de la potencia eólica

En el caso del método propuesto y el WSM las funciones de densidad de probabilidad de la potencia eólica se estimarán mediante la (Ec 11-23), [141]

$$\text{(Ec 11-23)} \quad WPD(v) = \frac{f_c^{LT}(v)v^3}{\int_0^\infty f_c^{LT}(v)v^3 dv}$$

Donde $f_c^{LT}(v)$ representa la pdf estimada a largo plazo por el correspondiente método.

En el caso del JPA y del VRM las funciones de masa de probabilidad de la potencia eólica e estimarán mediante la (Ec 11-24)

$$\text{(Ec 11-24)} \quad WPD(m_i) = \frac{p(m_i)m_i^3}{\sum_{i=1}^{Nw} p(m_i)m_i^3}$$

Donde los m_i son los puntos medios (midpoints) de los *Nw* bines (bins) y las $p(m_i)$ son las frecuencias relativas en cada bin. En el caso del JPA $p(m_i)$ viene dada por la (Ec 11-3) y para el VRM por el histograma de frecuencia relativo del viento indicado en el apartado 6.1. Tanto en (Ec 11-23) como en (Ec 11-24) la densidad del aire se ha considerado constante e independiente de la velocidad del viento [141].

11.6.3 Potencia Eléctrica

En el caso del método propuesto y el WSM las funciones de densidad de probabilidad de la

potencia eléctrica se estimarán mediante la (Ec 11-25)[5].

$$\text{(Ec 11-25)} \quad EPD(v) = \frac{PWT(v)\, f_c^{LT}(v)}{\int_0^{\infty} PWT(v)\, f_c^{LT}(v)\, dv}$$

Donde *PWT*(*v*) representa la curva de potencia-velocidad de un aerogenerador.

En el caso del JPA y del VRM las funciones de masa de probabilidad de la potencia eléctrica se estimarán mediante la (Ec 11-26)

$$\text{(Ec 11-26)} \quad EPD(m_i) = \frac{PWT(m_i)\, p(m_i)}{\sum_{i=1}^{Nw} PWT(m_i)\, p(m_i)}$$

Tanto en (Ec 11-25) como en (Ec 11-26) la densidad del aire se ha considerado constante e independiente de la velocidad del viento [141].

Para las estimaciones de este apartado se ha utilizado un aerogenerador comercial de 900kW de potencia nominal y regulación de paso variable (pitch-regulated) [165], Fig.11.4.

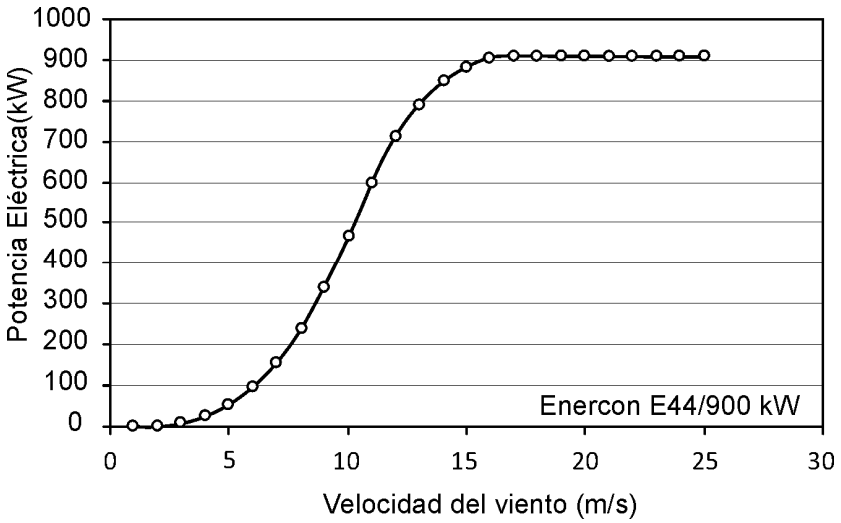

Figura 11.4: Curva de potencia característica del aerogenerador utilizado en el presente estudio.

[5] La integral de la (Ec 11-21) no puede ser resuelta mediante métodos analíticos. Para ello se han utilizado métodos numéricos. Para su resolución se ha empleado el programa Mathcad® 2001*i* de MathSoft Engineering & Education, Inc [18].

Hay que señalar que en este estudio las funciones de densidad de probabilidad del viento y las funciones de masa de probabilidad del viento utilizadas en las (Ec 11-25) y (Ec 11-26), respectivamente, son las estimadas en la estación objetivo a la altura de 10 metros sobre el nivel del suelo. Ello, se ha realizado así con el objetivo de no introducir en este análisis los errores que se generan con los modelos de extrapolación de la velocidad del viento con la altura.

Generalmente, los fabricantes de los aerogeneradores publican los datos de la curva de potencia de la máquina, *PWT*(*v*), en una tabla. En este estudio, los valores de la potencia eléctrica para un determinado valor de v, que se encuentre entre dos valores presentes en la tabla, se estimarán mediante una interpolación lineal entre ambos.

Como las curvas de potencia son bastante suaves, pueden aproximarse por medio de interpolación spline cúbica.

11.7 Métricas utilizadas en la evaluación

Con el objeto de analizar la bondad del ajuste para cada una de las características indicadas en el apartado 11.6 se han utilizado dos métricas. Dichas métricas son: El coeficiente de determinación R^2 [189] y la raíz de error cuadrático relativo (RRSE, siglas de su traducción al inglés, Root Relative Square Error) [188]. RRSE viene definida por la (Ec 11-27), donde “e” es la probabilidad acumulada estimada y “o” la observada. R^2 es el cuadrado del coeficiente de correlación obtenido entre la probabilidad acumulada estimada y la observada.

$$\text{(Ec 11-27)} \quad RRSE = 100\sqrt{\frac{\sum_{i=1}^{Nw}(o_i - e_i)^2}{\sum_{i=1}^{Nw}(o_i - \overline{o})^2}} \quad (\%)$$

11.8 Análisis de los resultados

En la tabla 11.3 se muestran los valores de los parámetros de las funciones de densidad de Weibull Mixta ajustadas a los datos a corto plazo (2008) y a largo plazo (1999-2008).

En la tabla 11.4 se indican los valores de los coeficientes de asociación de las distribuciones bivariable obtenidas con las diversas combinaciones de las estaciones eólicas.

Tabla 11.3 :Parámetros de la función de densidad de probabilidad de Weibull Mixta de las diferentes estaciones meteorológicas

	Año 2008					**Años 1999-2008**				
WS	α_1	β_1	α_2	β_2	ω	α_1	β_1	α_2	β_2	ω
	-	(m/s)	-	(m/s)	-	-	(m/s)	-	(m/s)	-
WS-1	2.729	3.745	2.950	7.947	0.292	1.827	5.816	4.929	8.922	0.823
WS-2	3.034	3.519	3.828	7.606	0.209	2.517	3.256	3.365	7.263	0.227
WS-3	1.810	5.784	4.254	11.267	0.468	1.588	4.849	3.841	10.334	0.465
WS-4	2.597	3.752	3.358	8.591	0.417	2.268	3.432	2.936	8.265	0.429
WS-5	1.735	5.765	4.670	7.957	0.347	1.413	3.998	3.137	7.591	0.304
WS-6	9.822	3.660	2.092	6.141	0.060	6.273	3.154	2.289	5.452	0.066

Tabla 11.4 : Coeficiente de Asociación ψ de la distribución bivariable para el año 2008.

	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
WS-1	-	11.0275	16.892751	5.265359	3.912902	5.69398
WS-2	11.0275	-	11.246719	5.151877	5.186045	5.743455
WS-3	16.892751	11.246719	-	5.346644	4.845632	6.82522
WS-4	5.265359	5.265359	5.346644	-	2.214407	2.805872
WS-5	3.912902	5.186045	4.845632	2.214407	-	4.680542
WS-6	5.69398	5.743455	6.82522	2.805872	4.680542	-

Tabla 11.5 Coeficiente de Asociación ψ de la distribución bivariable para el año 2008.

	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
WS-1	-	11.0275	16.892751	5.265359	3.912902	5.69398
WS-2	11.0275	-	11.246719	5.151877	5.186045	5.743455
WS-3	16.892751	11.246719	-	5.346644	4.845632	6.82522
WS-4	5.265359	5.265359	5.346644	-	2.214407	2.805872
WS-5	3.912902	5.186045	4.845632	2.214407	-	4.680542
WS-6	5.69398	5.743455	6.82522	2.805872	4.680542	-

En las figuras 11.5 y 11.6 se muestran las métricas RRSE y las R^2, respectivamente, generadas por los distintos modelos analizados en la estimación de las distribuciones de la velocidad del viento a largo plazo. Puede observarse que en un destacado porcentaje de los casos analizados el método propuesto ha estimado mejor las distribuciones de la velocidad del viento que los restantes métodos que se han empleado en la comparación. Dichos porcentajes han sido del 96.7%, 83.3% y 93.3% (en el caso de R^2) y del 80%, 80% y 96.7% (en el caso de RRSE), cuando el método propuesto se ha comparado con JPA, WSM y VRM, respectivamente.

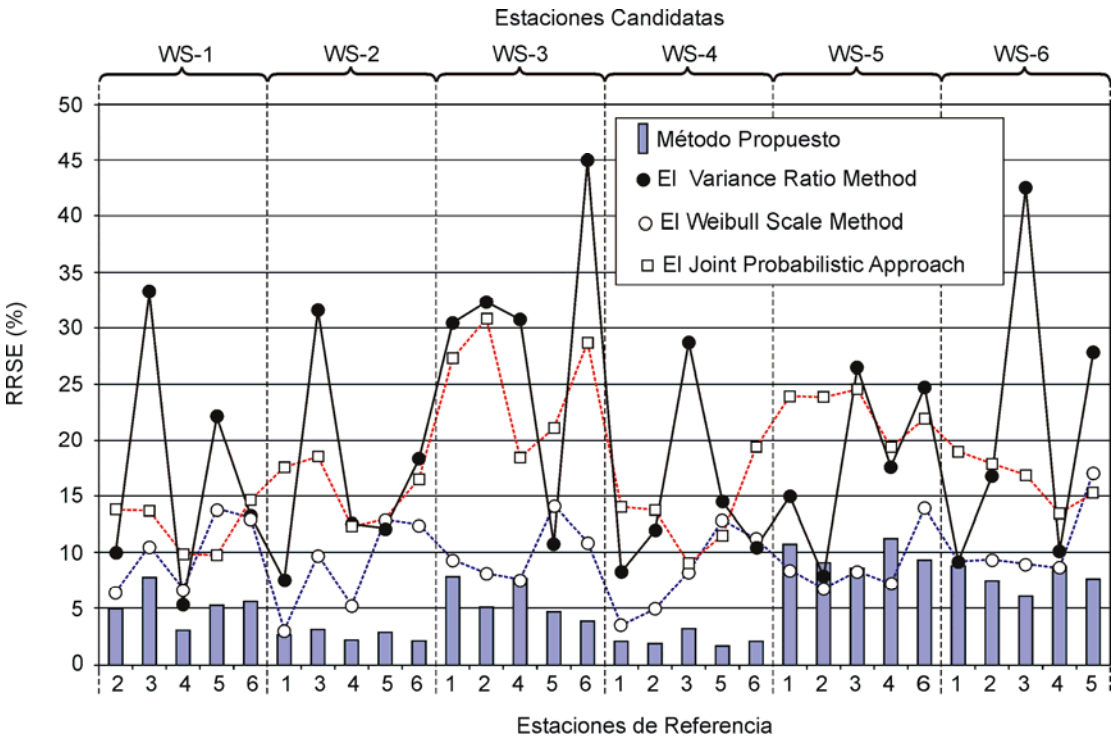

Figura 11.5:Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la velocidad del viento a largo plazo.

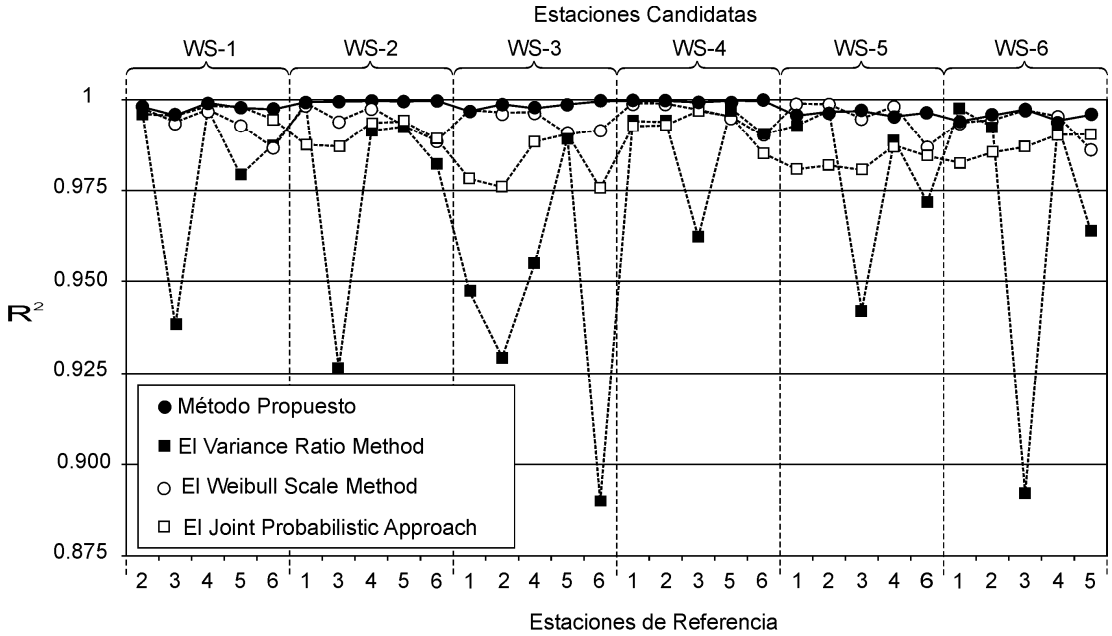

Figura 11.6:Métrica R^2 de los modelos utilizados en la estimación de las distribuciones de la velocidad del viento a largo plazo.

En las figuras 11.7 y 11.8 se muestran las métricas RRSE y R^2, respectivamente, pero referidas a la estimación de las distribuciones de la densidad de potencia eólica. Asimismo, puede observarse que, con excepción del JPA, el método propuesto ha estimado mejor las funciones de distribución de probabilidad de la potencia eólica, en la mayoría de los casos analizados, que los restantes métodos que se han empleado en la comparación. Los porcentajes de casos en los que el método propuesto ha estimado mejor que JPA, WSM y VRM, respectivamente, han sido del 43.3%, 80% y 86.7% (en el caso de R^2) y de 50%, 76.7% y 90% (en el caso de RRSE).

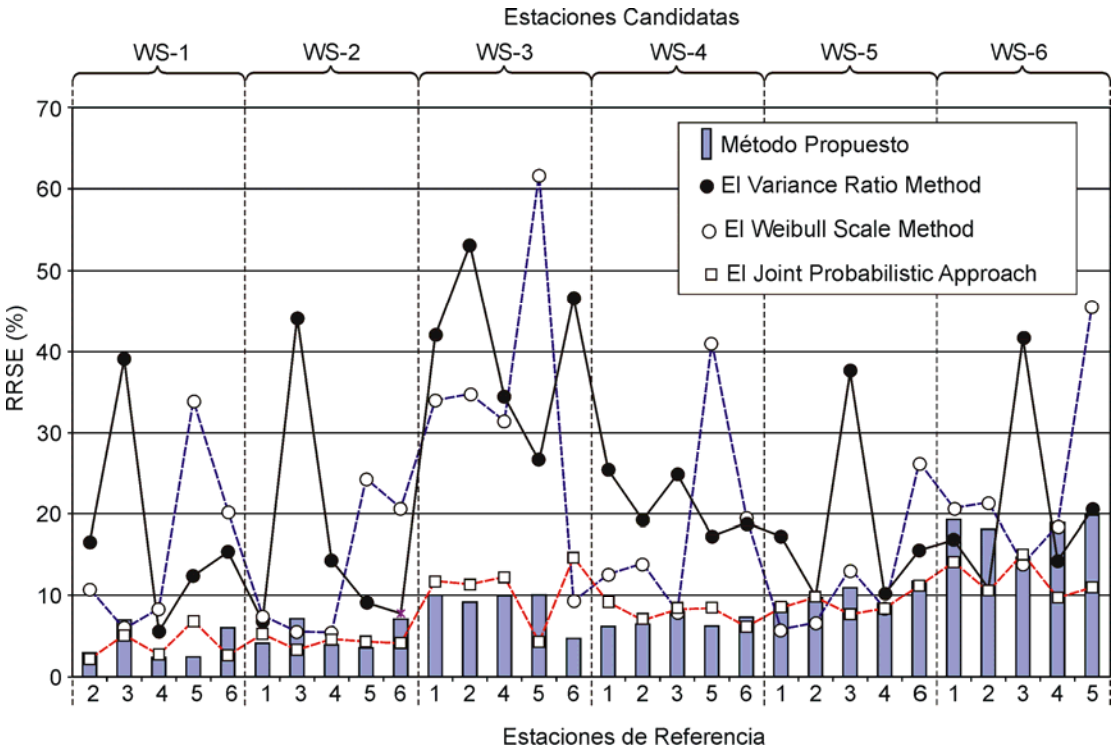

Figura 11.7: Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la densidad de potencia eólica a largo plazo.

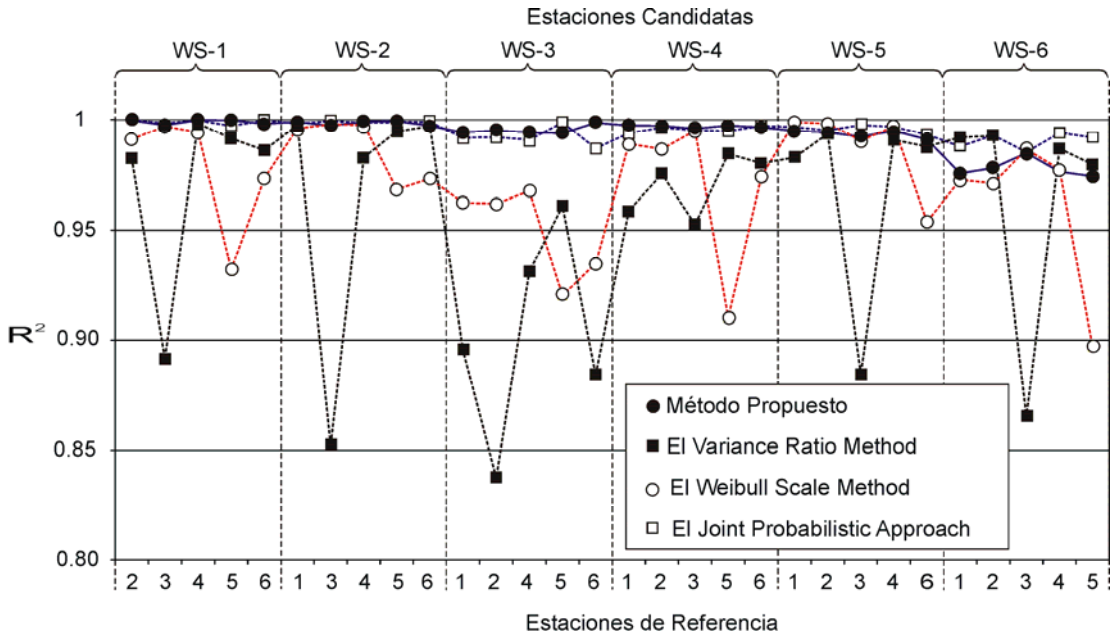

Figura 11.8: Métrica R^2 de los modelos utilizados en la estimación de las distribuciones de la densidad de potencia eólica a largo plazo.

Por último, en las figuras 11.9 y 11.10 se muestran los resultados de las dos métricas obtenidas con todos los modelos utilizados en la estimación de las distribuciones de potencia eléctrica. Al igual que en las figuras anteriores, en el 46.7%, 80% y 86.7% (en el caso de R^2) y en el 46.7%, 76.7% y 863.7% (en el caso de RRSE), el método propuesto ha estimado mejor que los JPA, WSM y VRM, respectivamente, dichas distribuciones.

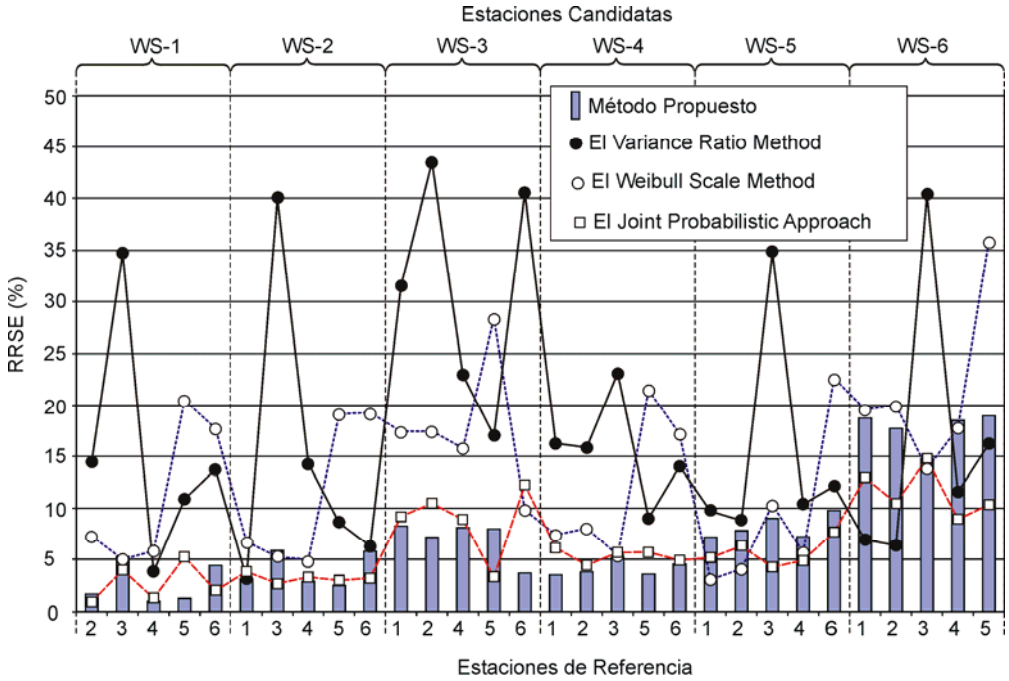

Figura 11.9: Métrica RRSE de los modelos utilizados en la estimación de las distribuciones de la potencia eléctrica generada por un aerogenerador a largo plazo.

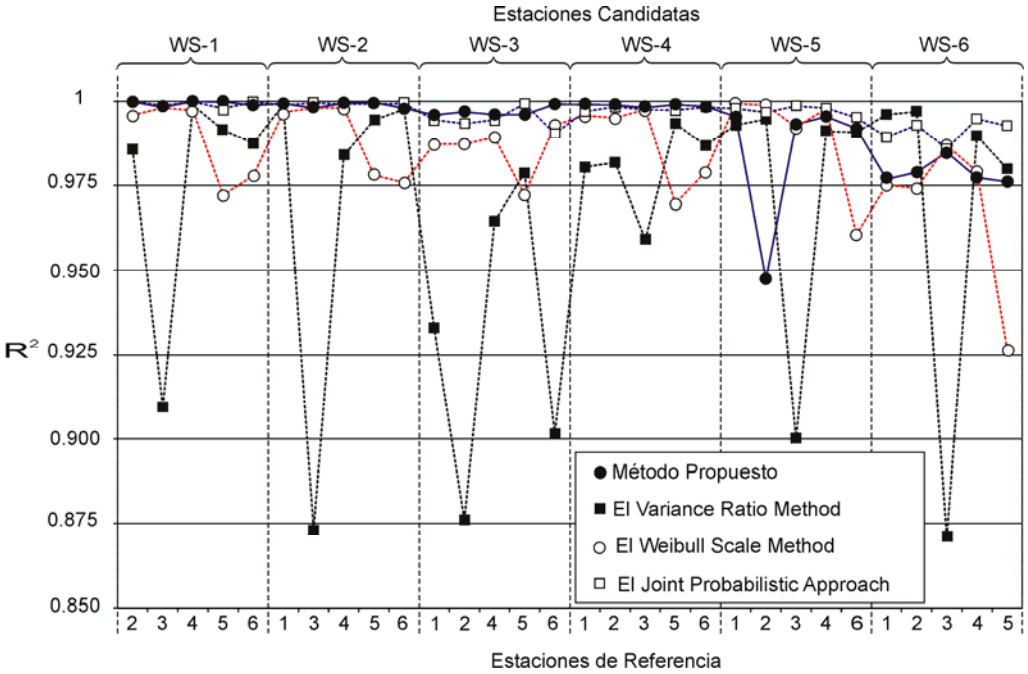

Figura 11.10: Métrica R^2 de los modelos utilizados en la estimación de las distribuciones de la potencia eléctrica generada por un aerogenerador a largo plazo.

Como se observa en las figuras 11.7 y 11.8 el JPA es el único método que presenta unas ligeras mejores estimaciones de la función de distribución de probabilidad de la potencia eólica que el método propuesto.

Dado que cuanto más altos sean los valores de R^2 en el ajuste de las distribuciones de probabilidad eólicas a los datos experimentales, menores son los errores que se producen en la estimación de la potencia eléctrica generada por un aerogenerador [90], como continuación a este estudio se está trabajando en el desarrollo de un modelo más completo que tenga en cuenta la influencia de la dirección del viento en la estimación a largo plazo. El desarrollo de dicho modelo se apoya en los estudios previos realizados sobre modelado de la dirección del viento [190] y de una función de densidad de probabilidad conjunta de la velocidad y dirección del viento [107].

La Figura 11.11 muestra, para el periodo 1999-2008, el histograma de las frecuencias relativas de la velocidad del viento para cada una de las estaciones, con bines de ancho 1 m s^{-1}. Cada histograma muestra además las pdfs a largo plazo estimadas, con el método propuesto, que mejor y peor se han ajustado a los datos experimentales.

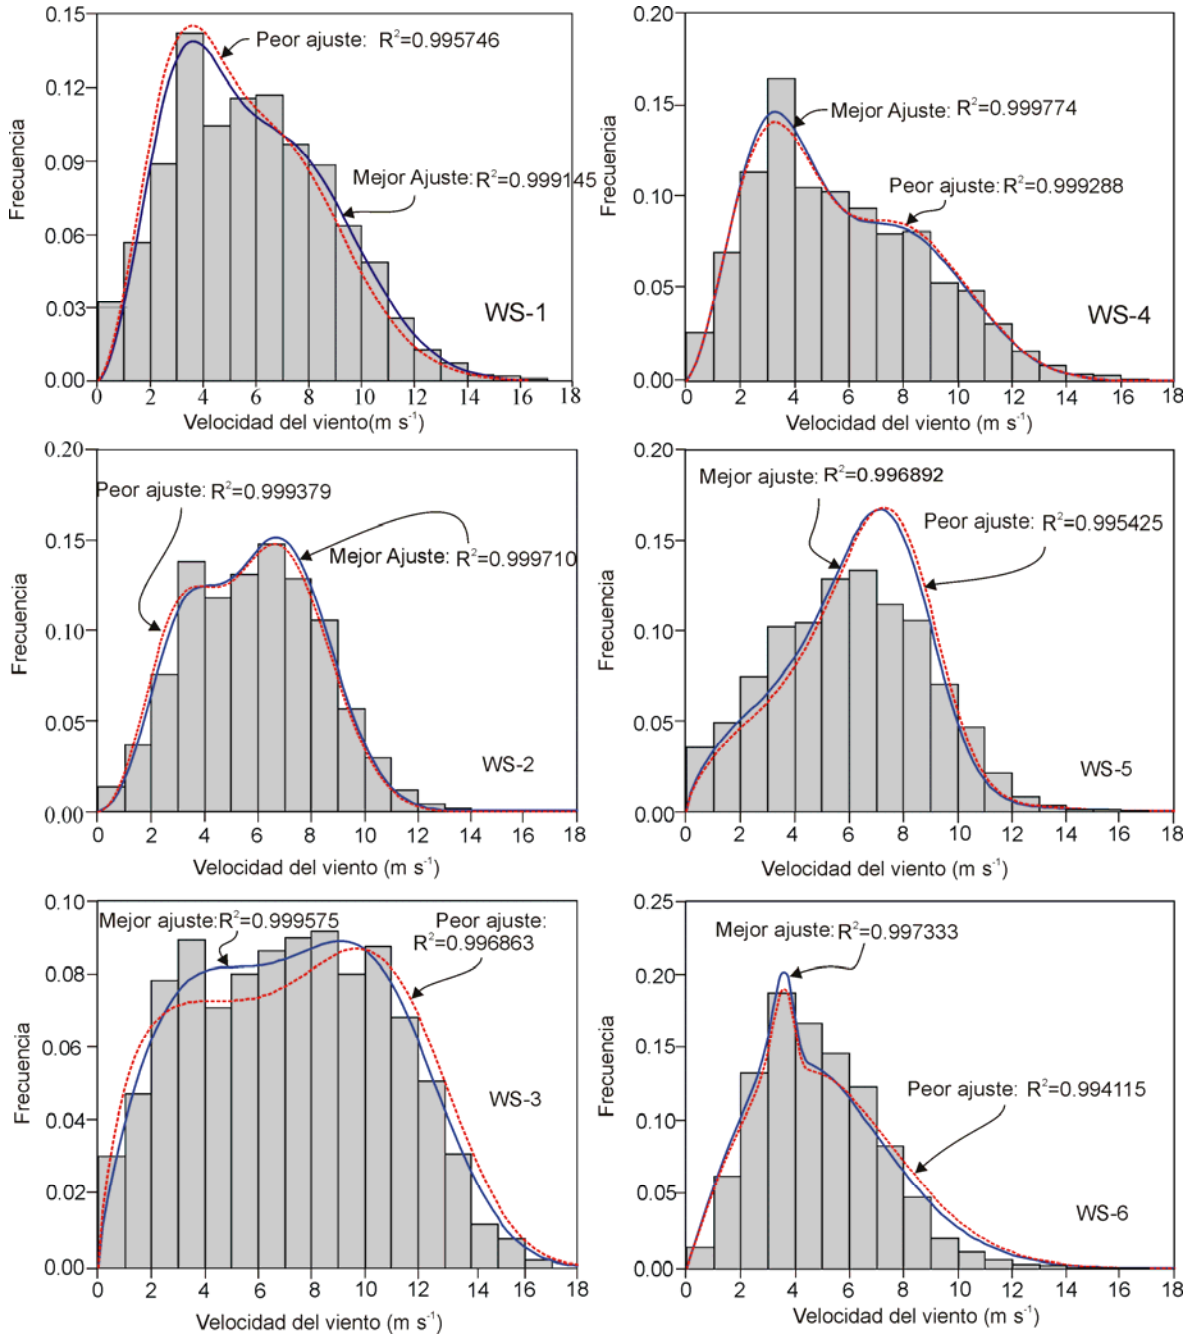

Figura 11.11: Histogramas de la frecuencia relativa de la velocidad del viento para el periodo 1999-2008 para las seis estaciones utilizadas. Cada histograma muestra además las pdfs estimadas a largo plazo con el método propuesto y que mejor y peor se han ajustado a los datos experimentales.

La Figura 11.12 muestra, para el mismo periodo los histogramas de la frecuencia relativa de la densidad de potencia eólica para cada una de las estaciones con bines de ancho 1 m s^{-1}. Cada

gráfica de la figura 11.12 muestra además, para los mejores ajustes representados en la figura 11.11, las funciones de densidad de probabilidad de la densidad de la potencia eólica a largo plazo estimadas con el método propuesto y con el WSM.

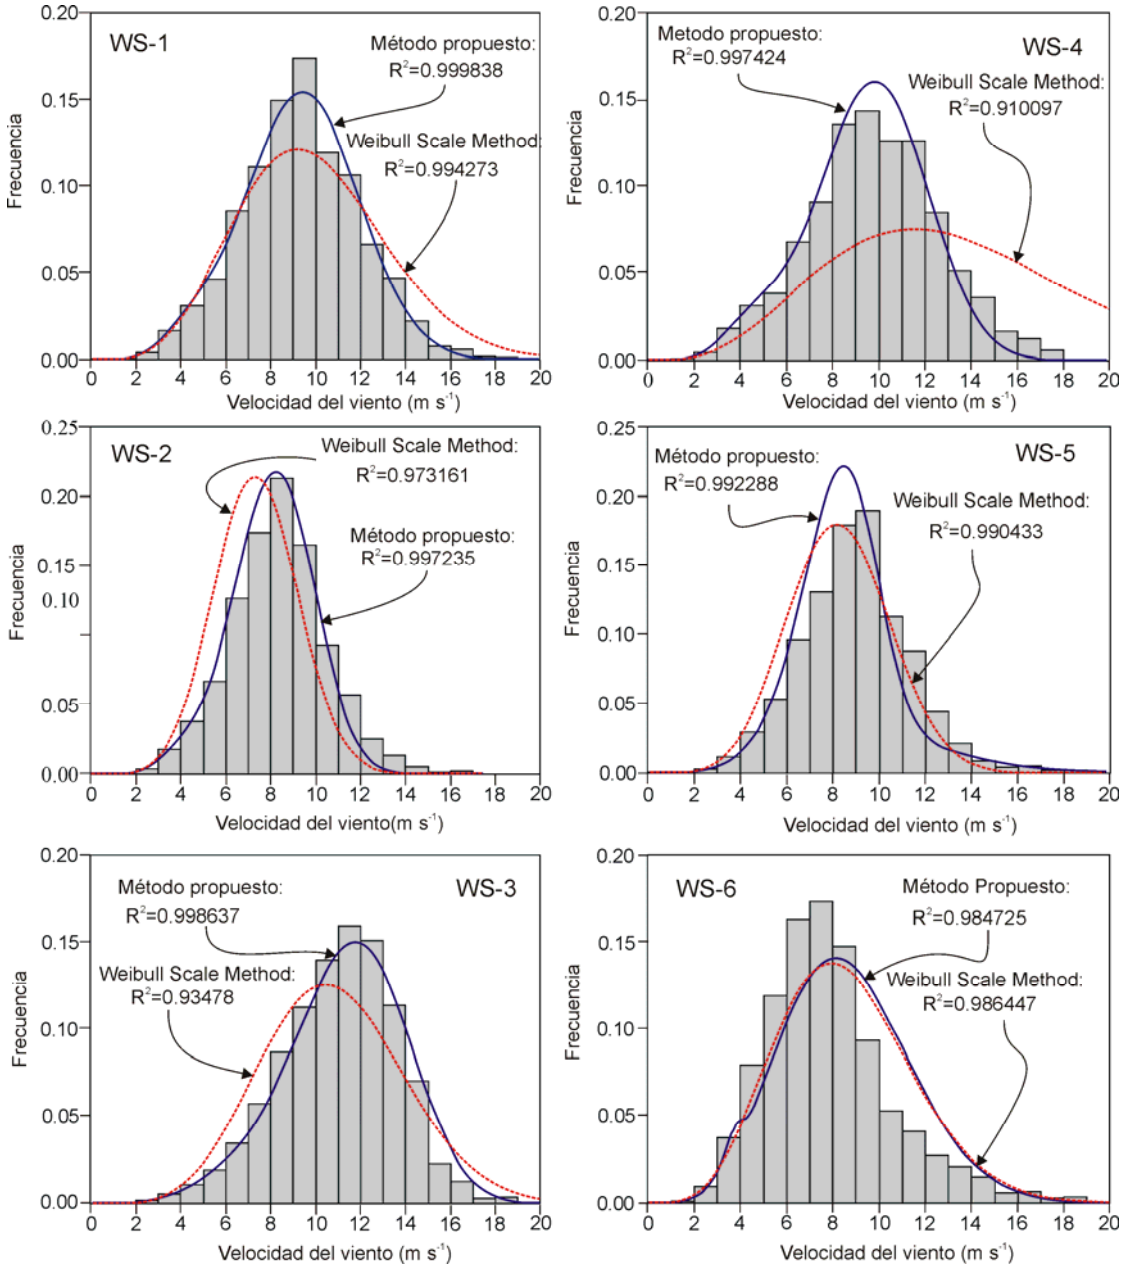

Figura 11.12: Histogramas de la frecuencia relativa de la densidad de la potencia eólica del periodo 1999-2008 para las seis estaciones utilizadas. Cada histograma muestra además, para los mejores ajustes de la figura 11.11, la densidad de potencia eólica estimada a largo plazo con el método propuesto y con el Weibull Scale Method (WSM).

Puede comprobase visualmente el mejor ajuste que, en la mayoría de los casos, presenta el método propuesto frente al otro método probabilístico de distribución continua divulgado en la literatura científica.

Con respecto al método propuesto hay que señalar que los peores ajustes, tanto a los histogramas de frecuencias relativas de la velocidad del viento como a los histogramas de frecuencia relativa de la densidad de potencia eólica, se han producido en las WS-5 y WS-6. El motivo de la pobre calidad del ajuste puede deberse a que la variabilidad interanual de las características del viento haya dado lugar a que los datos de viento del año 2008 usado para diseñar y entrenar el modelo no sean representativos del comportamiento a largo plazo. Si se observan los datos de la Tabla 11.1 y las formas de las pdfs de las figuras 11.2 y 11.11, este hecho es muy evidente en el caso de la WS-5. Puede observarse en dicha tabla los cambios significativos de los coeficientes de variación, curtosis y asimetría entre el año 2008 y el periodo de largo plazo.

En las figuras 11.13 a 11.15 se muestran las métricas RRSE obtenidas en la etapa de entrenamiento (ver el número 1 en Fig.11.3), las cuales han sido evaluadas mediante validación cruzada. De esta manera el resultado recoge la media de los experimentos de 10 subconjuntos de pruebas independientes. Asimismo, aprovechando la ventaja de la validación cruzada, que permite estimar la variabilidad del método de aprendizaje con respecto a la evidencia, se muestran en las figuras 11.13 a 11.15 los intervalos de confianza de las métricas, con un nivel de significación de 5%. Hay que señalar que estos intervalos se han determinado en la hipótesis de que los datos son independientes y siguen una distribución normal. Sin embargo, si bien los diez subconjuntos de prueba son independientes, no ocurre lo mismos con los subconjuntos de entrenamiento. Los subconjuntos de entrenamiento se solapan de tal manera que cada dos comparten el 80% de los datos. Ello podría afectar a la incertidumbre de la variabilidad del error obtenido durante el periodo de entrenamiento [191]. Además, se muestran en las mencionadas figuras las métricas RRSE obtenidas en la etapa de estimación (ver número 2 en Fig.11.3). Puede observarse que los modelos propuestos presentan un cierto poder de generalización, ya que los RRSE obtenidos en la etapa de entrenamiento no difieren en exceso de los obtenidos en la etapa de estimación. De hecho, en bastantes ocasiones el error obtenido durante la estimación ha sido inferior al producido durante el entrenamiento.

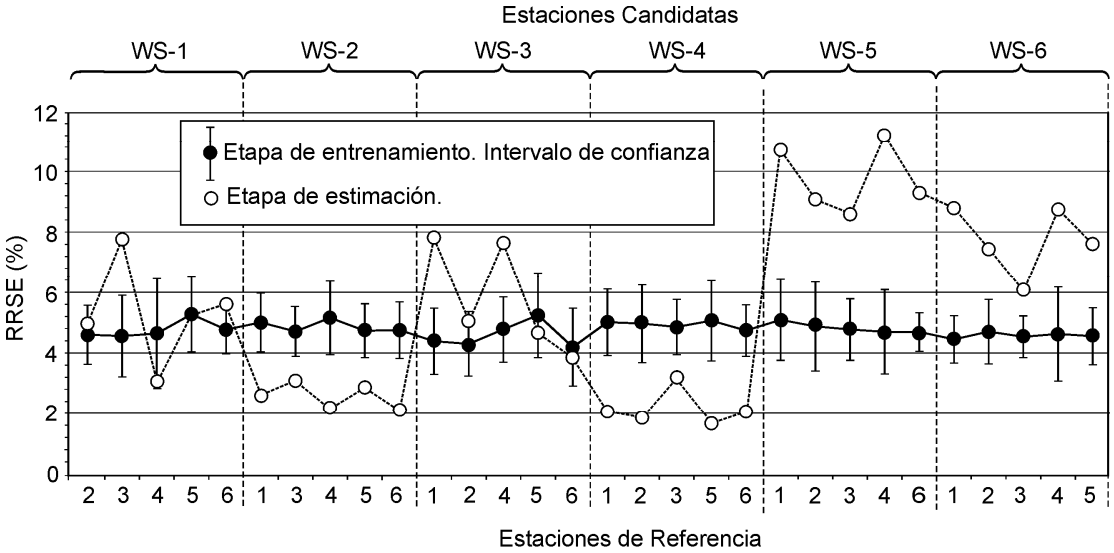

Figura 11.13:Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la velocidad del viento durante la etapa de entrenamiento y de estimación a largo plazo.

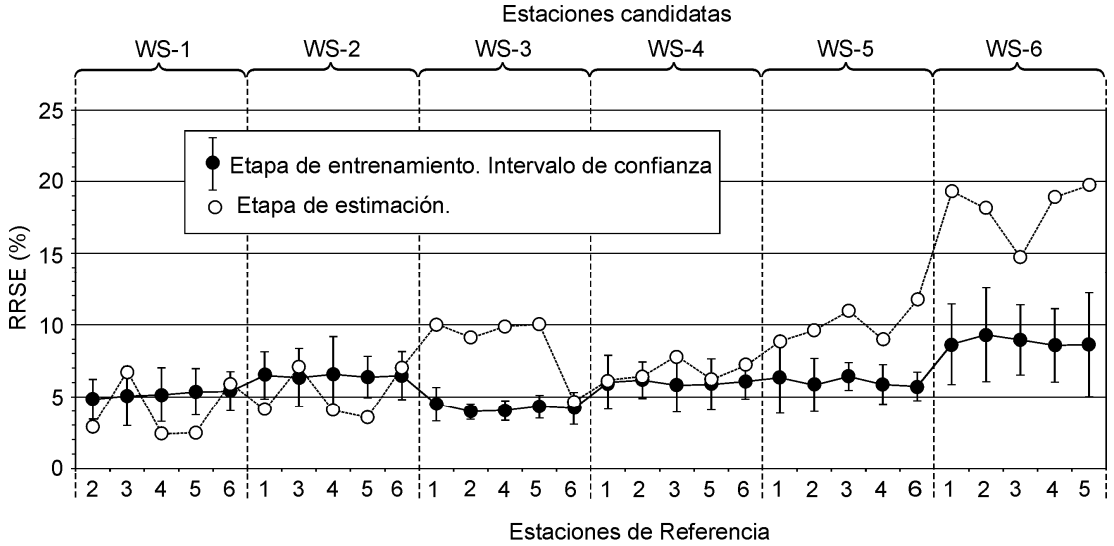

Figura 11.14:Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la densidad de potencia del viento durante la etapa de entrenamiento y de estimación a largo plazo.

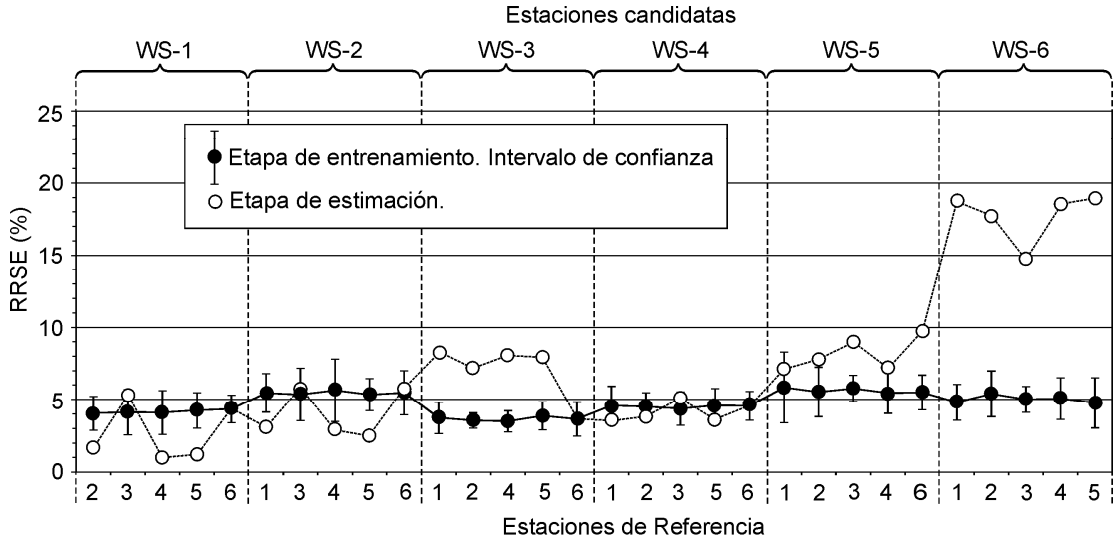

Figura 11.15: Métrica RRSE de los errores obtenidos en la estimación de las distribuciones de la potencia eléctrica durante la etapa de entrenamiento y de estimación a largo plazo.

En la figura 11.13 se observa que, si se descartan las estimaciones de la WS-5, en el 68% de los restantes casos los RRSE estimados a largo plazo se encuentran dentro del intervalo de confianza obtenido en la etapa de entrenamiento o debajo de su límite inferior. La causa de las mayores discrepancias entre los errores de la etapa entrenamiento y de la etapa de estimación de la WS-5 se debe, fundamentalmente, a la ya señalada escasa representación que los datos usados para entrenamiento del modelo tienen del régimen de vientos a largo plazo. En la figura 11.16 se comparan los R^2 obtenidos en la etapa de entrenamiento con los originados en la etapa de estimación. Puede observarse en la Fig.11.16 que los modelos obtenidos también presentan según esta métrica un cierto poder de generalización. Los errores obtenidos en la etapa de entrenamiento y estimación a largo plazo son, en general, muy parecidos. Las mayores discrepancias se han presentado de nuevo al estimar las características a largo plazo de WS-5 y WS-6.

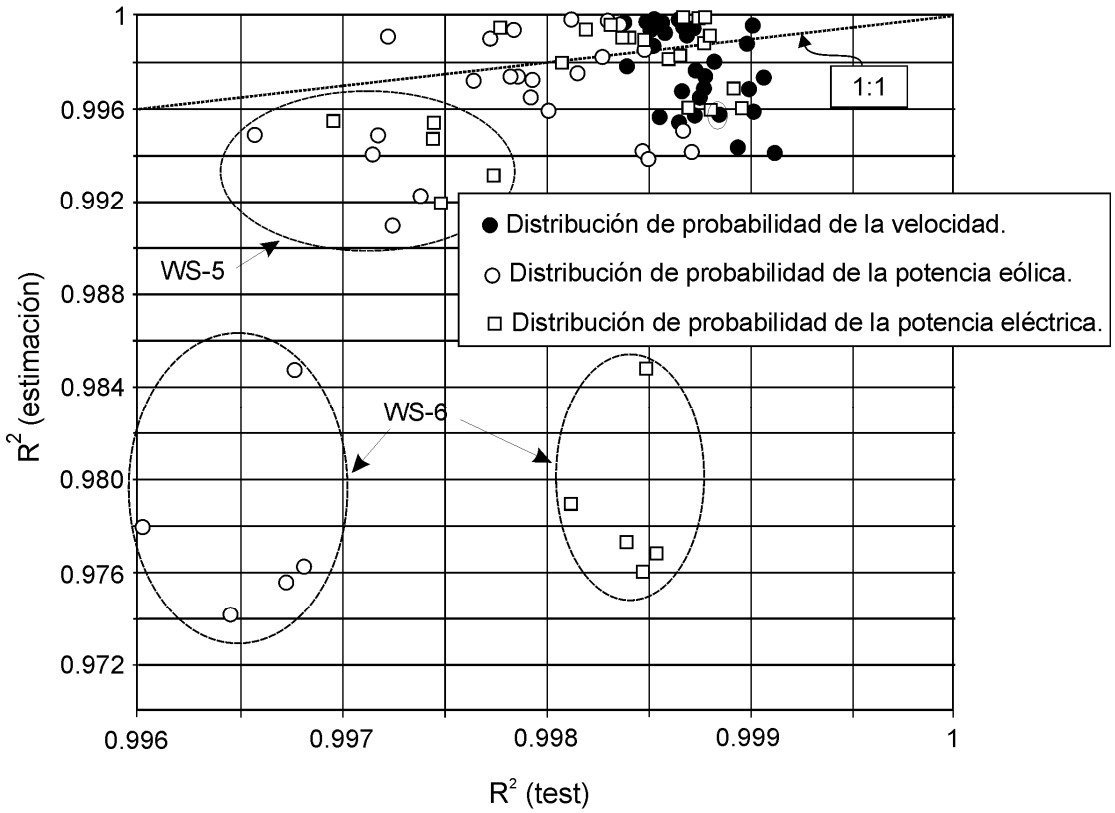

Figura 11.16: Métrica R^2 obtenida en la estimación de los histogramas de frecuencia relativa de la velocidad del viento de las seis estaciones en función de la R^2 obtenida en la primera fase de la evaluación del modelo.

Hay que señalar que los coeficientes de correlación lineal existentes entre las diversas estaciones (Tabla 11.2) son bajos o muy bajos y, por tanto, no se ha podido analizar la influencia que valores altos de dichos coeficientes tienen en el error de estimación a largo plazo. Asimismo, tampoco se ha podido llevar a cabo un análisis de la influencia de altos valores del coeficiente de correlación a la hora de comparar el método propuesto con los otros métodos seleccionados en este estudio.

De los ensayos llevados cabo en este estudio con las estaciones disponibles se observa que algunos casos las técnicas MCP puede que no sean apropiadas para la estimación de las características del viento a largo plazo. Es decir, que los datos de viento medidos durante un año en la estación candidata pueden proporcionar mejores resultados que las estimaciones a largo realizadas con dichas técnicas. En la Figura 11.17 se muestra una comparación entre los RRSE obtenidos en la estimación de las distribuciones de la velocidad del viento a largo plazo

cuando se usa el método descrito en este estudio y cuando se consideran los datos del año 2008 como representativos del largo plazo.

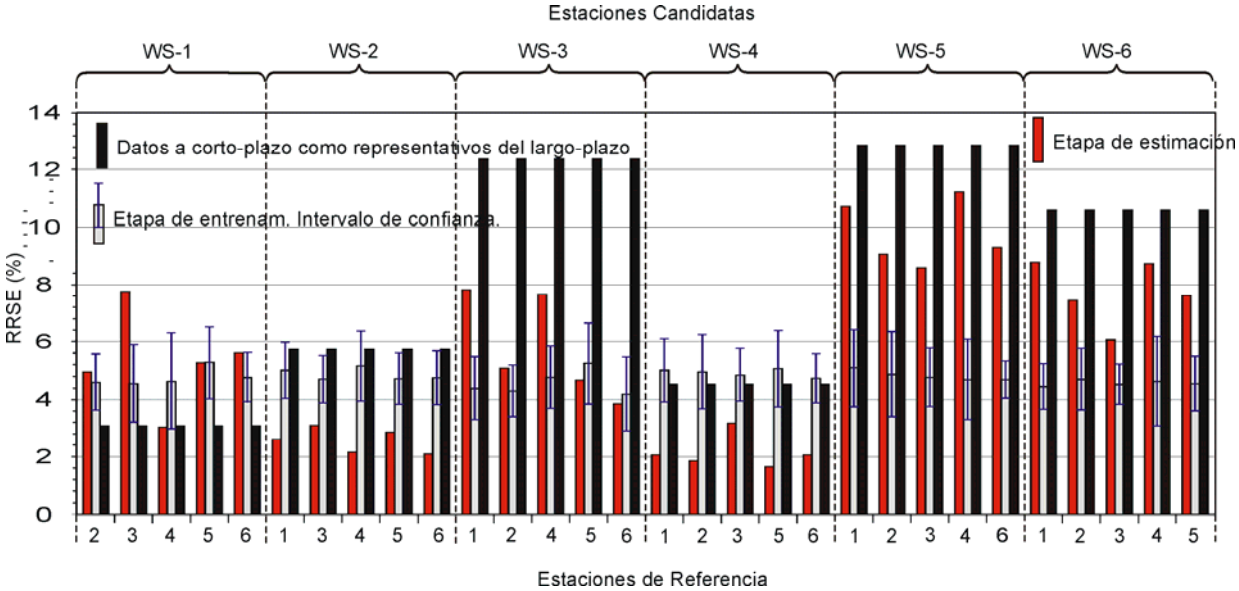

Figura 11.17: RRSE; métrica de los errores obtenidos en la estimación de las distribuciones de la velocidad del viento durante la etapa de entrenamiento, durante la etapa de estimación a largo plazo y cuando se usan las pdfs de la velocidad del viento para el año 2008 como representativas del largo plazo.

Puede observarse que en todos los casos analizados, con excepción de la WS-1, cuando se confía en que los datos medidos durante el periodo corto (2008) son representativos del largo plazo se han producidos mayores errores que cuando las pdfs de la velocidad del viento a largo plazo han sido estimadas por el método descrito en este estudio. Por tanto, antes de aplicar este método sería conveniente realizar un mayor número de ensayos en regiones con otros regímenes de viento. La realización de ensayos con estaciones con mayores niveles de correlación entre sus series de datos de viento probablemente proporcione información que pueda arrojar mayor luz a la hora de decidirse por utilizar esta técnica de estimación.

11.9 Conclusiones

Como resultado de la aplicación del método propuesto en este estudio a los datos eólicos correspondientes a seis estaciones meteorológicas ubicadas en el archipiélago canario, se pueden destacar las siguientes conclusiones:

El método propuesto ha estimado mejor las distribuciones de la velocidad del viento, en la mayoría de los casos analizados, que los restantes métodos que se han empleado en la comparación.

El algoritmo para la estimación de las características eólica a largo plazo usando JPA que se propone en la literatura científica [16] es el único método que en la estimación de la distribución de la densidad de potencia eólica presenta unos porcentajes de casos ligeramente superiores al método propuesto.

Como todos los métodos MCP, el método propuesto es vulnerable a los cambios climáticos [192], a la limitada dependencia entre los datos de la estación de referencia y la candidata y a la escasa representación de las características del viento a largo plazo del periodo de datos usado para el entrenamiento.

CAPITULO 12

Comparación entre las Redes Neuronales Artificiales y los algoritmos MCP lineales en la estimación a largo plazo del coste del kWh producido por un aerogenerador en un emplazamiento candidato.

INDICE

12 COMPARACIÓN ENTRE LAS REDES NEURONALES ARTIFICIALES Y LOS ALGORITMOS MCP LINEALES EN LA ESTIMACIÓN A LARGO PLAZO DEL COSTE DEL KWh PRODUCIDO POR UN AEROGENERADOR EN UN EMPLAZAMIENTO CANDIDATO.....279
12.1 Introducción 279
12.2 Métodos MCP utilizados para la comparación 281
12.3 Arquitectura de las Redes Neuronales Artificiales utilizadas.....282
12.4 Datos meteorológicos y de los aerogeneradores utilizados. 283
12.5 Metodología.....288
12.5.1 Escenario A 290
12.5.2 Escenario B 291
12.6 Parámetros analizados.....292
12.6.1 Velocidad del viento..... 292
12.6.2 Densidad de la potencia eólica..... 292
12.6.3 Potencia eléctrica 293
12.6.4 Coste de la energía eléctrica 293
12.7 Métricas utilizadas en la evaluación numérica de los resultados. 294
12.8 Análisis de los resultados 295
12.9 Conclusiones 306

12 COMPARACIÓN ENTRE LAS REDES NEURONALES ARTIFICIALES Y LOS ALGORITMOS MCP LINEALES EN LA ESTIMACIÓN A LARGO PLAZO DEL COSTE DEL KWh PRODUCIDO POR UN AEROGENERADOR EN UN EMPLAZAMIENTO CANDIDATO.

12.1 Introducción

El coste específico de producción de energía eléctrica (coste por Kilovatio-hora) de un aerogenerador depende de los costes de inversión, de los costes de financiación, de los costes de operación y mantenimiento y de la energía anual generada por la misma [7,193-197]. La energía anual generada por un determinado aerogenerador tiene una gran influencia en el coste específico. Dada la relación cúbica entre la velocidad del viento y la densidad de potencia eólica [141], la viabilidad económica de un proyecto de aprovechamiento de la energía eólica en un emplazamiento candidato depende en gran medida de las condiciones eólicas que actúan sobre el aerogenerador durante la vida útil de la instalación [194,196,198]. Dada la variabilidad en el tiempo (diaria, estacional, interanual) de las características del viento [6,18,32,46,185,186,199] es preciso disponer de series históricas de medidas de datos de viento en el sitio candidato que permitan evaluar la misma. De esta forma, es posible reducir la incertidumbre a la hora de estimar la viabilidad económica de un proyecto de instalación de un aerogenerador en un determinado sitio. Algunos autores [199] indican que se necesitan al menos cinco años de datos de viento en el sitio candidato, aunque señalan que es preferible que sean diez. Según Hiester and Pennell [6], es difícil de estimar con cierta precisión los valores medios del comportamiento del viento con menos de 10 años de datos en el sitio candidato. Incluso, algunos autores [46,185-186] consideran que se necesitan veinte o treinta años para caracterizar a largo plazo un recurso eólico. Sin embargo, en muchas ocasiones no se dispone de series históricas de medidas de datos de viento en el sitio candidato. Una opción para solventar este inconveniente consiste en establecer campañas de medida de duración suficiente en el sitio objetivo. Esta opción supone, fundamentalmente, posponer durante un tiempo, normalmente no aceptable, la toma de decisiones. En el caso concreto de las Islas Canarias, la instalación de parques eólicos viene regulada por la oferta de potencia eólica que el Gobierno Autónomo del archipiélago promueve mediante documentos legislativos [5]. El periodo transcurrido entre la publicación de los mencionados documentos legislativos y el fin del plazo para la presentación de las propuestas por parte de los inversores es reducido. Por

tanto, el periodo de tiempo disponible para llevar a cabo la campaña de media de datos eólicos es corto. Generalmente, los inversores no suelen disponer de un periodo de tiempo superior a un año para analizar el recurso eólico del lugar de interés. En este espacio de tiempo es posible extraer información sobre las variaciones estacionales del viento en los potenciales sitios de aprovechamiento de la energía eólica. Sin embargo, se obvia la variabilidad interanual de las características del mismo. Para intentar soslayar esta escasez de datos a largo plazo en el sitio candidato se suele proponer con frecuencia el uso de métodos estadísticos, generalmente denominados como measure-correlate-predict (MCP). Estos métodos hacen uso de las series de datos históricos (de larga duración) de viento disponibles en estaciones cercanas que se toman como referencia. Además, ellos precisan que una porción de los datos de viento de la estación de referencia se hayan medido durante un periodo de tiempo (corto plazo) que ha de coincidir en longitud y fecha con el periodo de medida del sitio candidato. Se parte de la hipótesis de la existencia de una cierta relación entre el comportamiento del viento en el sitio candidato y en el de referencia.

Los métodos MCP inicialmente utilizados [18,32,87,163,171] estimaban únicamente la velocidad media anual del viento a largo plazo. Posteriormente, los métodos MCP más frecuentemente utilizados han recurrido al empleo de algoritmos de regresión lineal [9,15] para establecer la relación entre las características del viento horarias (o de menor intervalo de tiempo) del sitio candidato y las de la estación que se elige como referencia. Sin embargo, también se han propuesto modelos que establecen relaciones de tipo no lineal [10,16]. Asimismo, se han propuesto técnicas de aprendizaje automático [21-22,24-26,170]. Entre estas últimas pueden señalarse las técnicas que emplean algoritmos de aprendizaje estadístico, como son las redes Bayesianas (Bayesian Networks) (BNs) [170] y las técnicas basadas en algoritmos inspirados en la Biología, como son las Redes Neuronales Artificiales (ANNs) (Artificial Neural Networks) [21-22,24-26].

En el presente trabajo se utilizan ANNs para llevar a cabo la estimación a largo plazo de los costes específicos de la energía eléctrica generada por un parque eólica. Como caso de estudio se utilizan las velocidades y direcciones medias horarias del viento, registradas durante 10 años en 6 estaciones meteorológicas ubicadas en diferentes islas del Archipiélago Canario (España). Asimismo, se han utilizado las curvas características potencia-velocidad del viento de cinco turbinas eólicas de diferentes potencias nominales [165-166]. Para evaluar los errores cometidos entre los valores estimados y medidos o reales, se ha usado el Error absoluto relativo medio en tanto por ciento (en su traducción al inglés, Mean Absolute Percentage Error – MAPE-) y el coeficiente de correlación (en su traducción al inglés, correlation coefficient) ente

los datos medidos y estimados, los cuales han sido empleados por otros autores con anterioridad [22,25]. Dichos errores son comparados con los obtenidos con un método MCP lineal propuesto en la referencia [9]. La elección del denominado Variance Ratio Method (VRM) se fundamenta en las conclusiones alcanzadas por los autores de dicho artículo. Ellos señalan que de los cuatro métodos MCP comparados en su trabajo sólo el VRM parece dar siempre una estimación fiable de todas las métricas analizadas

12.2 Métodos MCP utilizados para la comparación

El Variance Ratio Method, propuesto por Rogers et al. [9], parte de la hipótesis de la existencia de una relación lineal entre las velocidades del viento a largo plazo en el sitio candidato v_c^{LT} y en el sitio de referencia v_r^{LT} , (Ec 12-1)

$$\text{(Ec 12-1)} \quad v_c^{LT} = a v_r^{LT} + b$$

Los valores de la pendiente *a* y de la ordenada en el origen *b* se deducen al forzar que la media y la varianza de la velocidades de viento estimadas durante el periodo de concurrencia de datos entre los sitios candidato y de referencia (corto plazo) coincidan con la media y varianza de las velocidades del viento observadas en dicho periodo. Con este criterio la Ec 12-1 se transforma en la (Ec 12-2)

$$\text{(Ec 12-2)} \quad v_c^{LT} = \left[\overline{v}_c^{ST} - \left(\frac{s_c^{ST}}{s_r^{ST}} \right) \overline{v}_r^{ST} \right] + \left(\frac{s_c^{ST}}{s_r^{ST}} \right) v_r^{LT}$$

Generalmente, los métodos MCP binean (binned) o agrupan la velocidades del viento en función de la dirección del mismo en el sitio de referencia. Para ello, los datos son divididos en un determinado número de sectores de dirección, que normalmente son ocho de 45º o doce de 30º. Entonces, se estiman los parámetros *a* y *b* del modelo, Ec 12-1, para cada sector de dirección. Es decir, la Ec 12-2 se aplica a cada sector de dirección. Por tanto, las medias $\overline{v}_r^{ST}$ **,** $\overline{v}_c^{ST}$ y las desviaciones estándar s_r^{ST} **,** s_c^{ST} a corto plazo (short-term) de los datos de viento de la estación de referencia y de la candidata, respectivamente, deben calcularse para cada uno de los sectores de dirección considerados.

12.3 Arquitectura de las Redes Neuronales Artificiales utilizadas

Las Redes Neuronales Artificiales (en inglés, Artificial Neural Network – ANN -) utilizadas en este capítulo están constituidas por topologías multilayer perceptrons (MLPs) [167-168]. Las arquitecturas se han diseñado con una única capa de neuronas ocultas (Fig.12.1). Este diseño ha demostrado su capacidad de aproximar satisfactoriamente cualquier transformación continua [167-168] y ha sido propuesto por diversos autores [21,24,26]. Además, el restringir a uno el número de capas ocultas se reducen los tiempos de entrenamiento. Como señales de entrada se utilizan las velocidades y direcciones medias horarias del viento en la estación de referencia. Por tanto, el número de neuronas de la capa de entrada es el doble del número N de estaciones de referencia empleadas. En las hipótesis consideradas en este capítulo la capa de salida tiene una sola neurona. La señal de salida proporcionada por dicha neurona es la velocidad media horaria estimada del viento en la estación candidata.

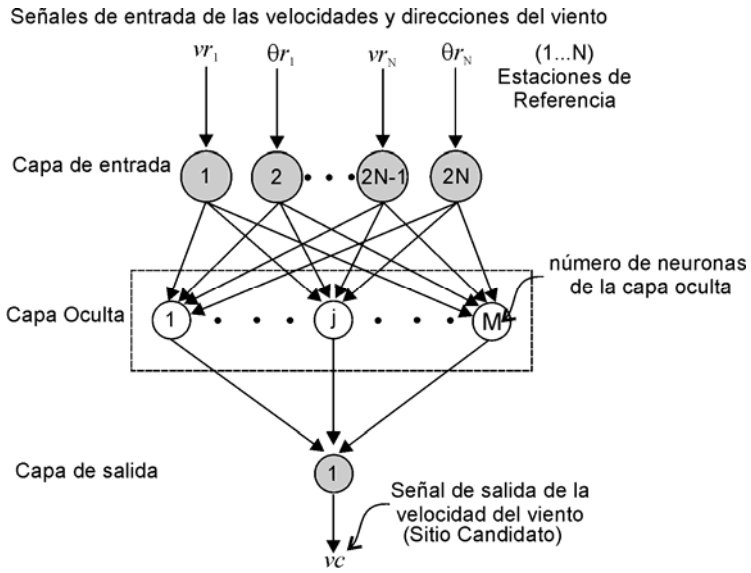

Figura 12.1: Esquema de una Red Neuronal con N-estaciones de Referencia y 2N parámetros de entrada (Velocidad y Dirección del viento)

Como algoritmo se entrenamiento se ha usado el de backpropagation con función de activación sigmoidal [164,167,168]. Como algoritmo de minimización del error cuadrático medio cometido en el aprendizaje se ha utilizado el de Levemberg-Marquard [167].

12.4 Datos meteorológicos y de los aerogeneradores utilizados.

A pesar del considerable número de estaciones anemométricas que han sido instaladas en Canarias en el pasado [200], por diversos motivos las únicas de las que tenemos constancia de que disponen de registros suficientemente largos y fiables son las utilizadas en este capítulo. Los datos meteorológicos utilizados para el estudio de este capítulo (velocidades y direcciones medias horarias del viento) han sido registrados durante el periodo 1999-2008 en seis estaciones meteorológicas ubicada en seis islas del archipiélago canario (Fig.12.2). Dicha información ha sido cedida por la Agencia Estatal de Meteorología (AEMET) del Ministerio de Medio Ambiente, y Medio Rural y Marino del Gobierno de España.

En la Figura 12.2 se pueden observar los nombres de las islas (Lanzarote, Fuerteventura, Gran Canaria, Tenerife, La Palma y El Hierro), sus superficies (en km^2), las distancias entre las estaciones anemométricas (en kms) y los códigos de referencia dados a cada una de ellas (WS-1, WS-2, WS-3 y WS-4, WS-5 y WS-6).

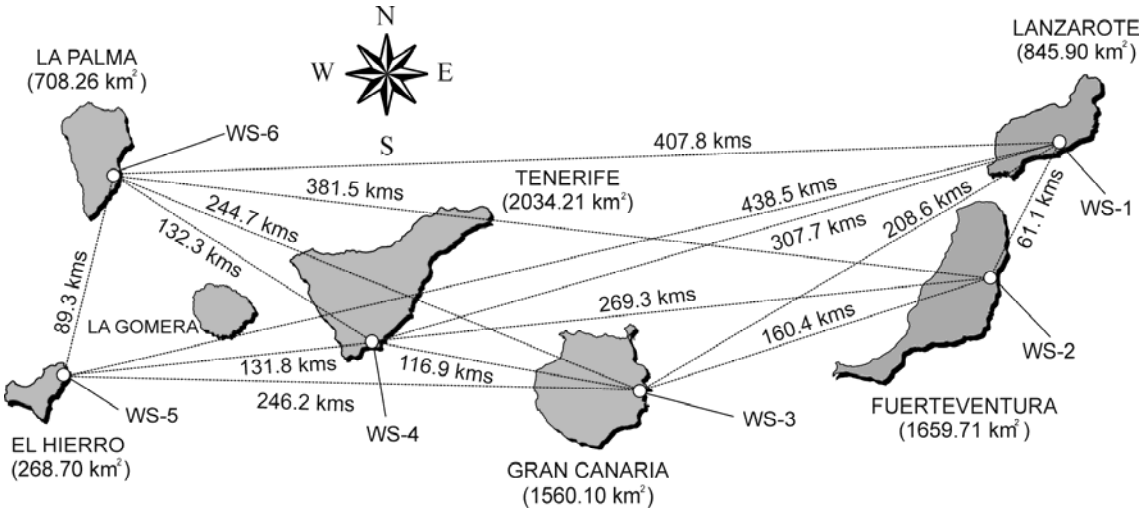

Figura 12.2: Ubicación de las estaciones meteorológicas utilizadas

En la Tabla 12.1 se especifican los nombres de las estaciones (Aeropuerto de Lanzarote, Aeropuerto de Fuerteventura, Aeropuerto de Gran Canaria, Aeropuerto Reina Sofía, Aeropuerto de La Palma y Aeropuerto de Los Cangrejos), los códigos asignados a las mismas y sus coordenadas geográficas. La altura sobre el nivel del suelo de dichas estaciones es de 10 metros.

Tabla 12.1 Datos generales de las estaciones meteorológicas (en su traducción al inglés, Weather Stations, WS) utilizadas en el estudio.

Nombre de la Estación	Código	Coordenadas Geográficas		
		Latitud (Norte)	Longitud (Oeste)	Altitud (m)
Aeropuerto de Lanzarote	WS-1	28º57'7"	13º36'	10
Aeropuerto de Fuerteventura	WS-2	28º27'10"	13º51'54"	24
Aeropuerto de Gran Canaria	WS-3	27º55'44"	15º23'20"	16
Aeropuerto Reina Sofía	WS-4	28º02'35"	16º34'16"	51
Aeropuerto Los Cangrejos	WS-5	27º48'50"	17º53'10"	30
Aeropuerto de La Palma	WS-6	28º36'47"	17º45'36"	85

En la figura 12.3 se representan las velocidades medias interanuales del viento de cada estación en el periodo de largo plazo (1999-2008). También, se muestran los intervalos comprendidos entre dichas velocidades medias y una y tres desviaciones estándar. Asimismo, se indican las velocidades medias anuales correspondientes al último año (2008) de las series disponibles de datos de todas las estaciones analizadas. Como se indica en el apartado de metodología, se considera que en todas las estaciones candidatas el periodo de corto plazo en el que se dispone de series de datos de viento corresponde al año 2008.

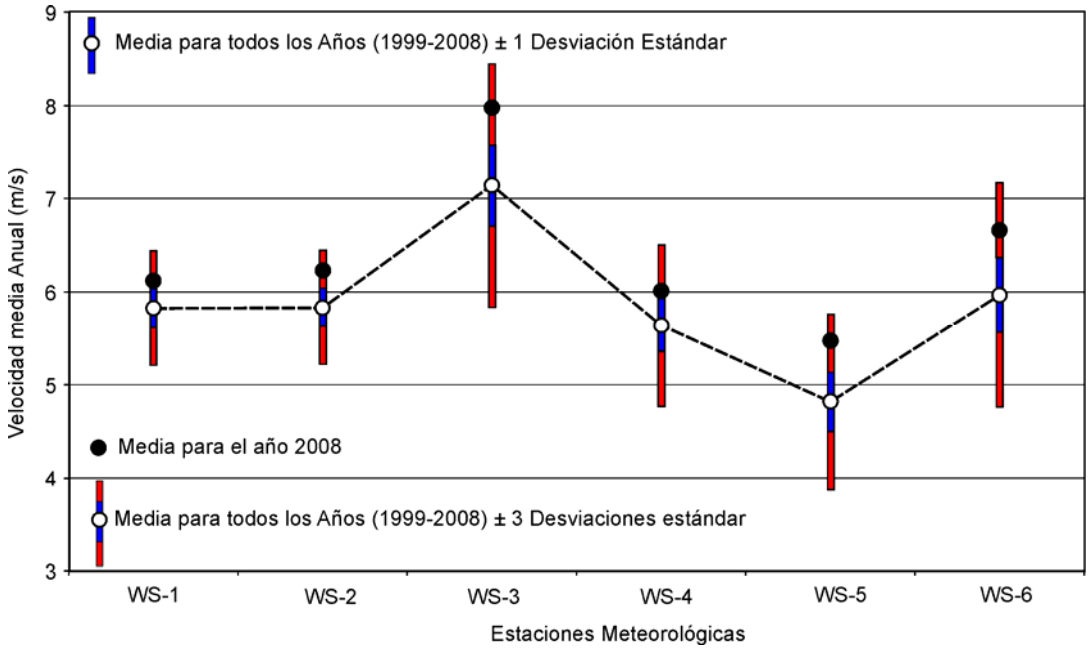

Figura 12.3: Velocidades medias interanuales del viento de cada estación meteorológica en el periodo de largo plazo (1999-2008).

En la Tabla 12.2 se muestran los coeficientes de correlación lineal entre las velocidades medias horarias del viento de las diversas estaciones. Dichos coeficientes se han obtenido para los datos de velocidad del viento del año 2008 y para el conjunto de todos los datos de velocidad del viento (1999-2008).

Tabla 12.2 Coeficientes de correlación lineal entre las velocidades medias horarias de las diferentes estaciones meteorológicas.

	Año 2008						Años 1999-2008					
	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
WS-1	1.000	0.660	0.736	0.497	0.410	0.509	1.000	0.649	0.663	0.489	0.430	0.485
WS-2	0.660	1.000	0.671	0.491	0.488	0.501	0.649	1.000	0.674	0.514	0.456	0.521
WS-3	0.736	0.671	1.000	0.502	0.472	0.552	0.663	0.674	1.000	0.492	0.469	0.566
WS-4	0.497	0.491	0.502	1.000	0.248	0.319	0.489	0.514	0.492	1.000	0.259	0.377
WS-5	0.410	0.488	0.472	0.248	1.000	0.449	0.430	0.456	0.469	0.259	1.000	0.480
WS-6	0.509	0.501	0.552	0.319	0.449	1.000	0.485	0.521	0.566	0.377	0.480	1.000

La figura 12.4 muestra las rosas de los vientos de cada una de las estaciones. La columna de la izquierda representa las rosas de viento del año 2008 y la columna de la derecha representa las rosas de viento construidas con direcciones del viento de todos los años disponibles (1999-2008).

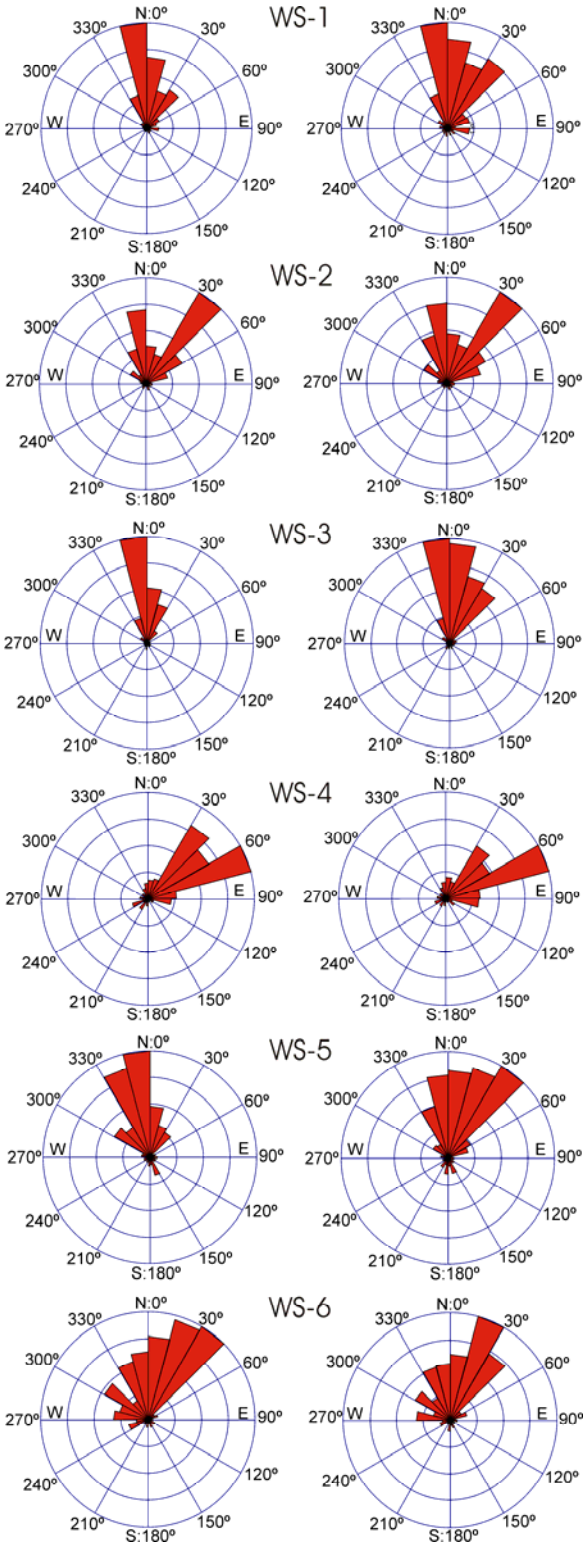

Figura 12.4: Rosas de los vientos de cada una de las estaciones. La columna de la izquierda representa las rosas de viento del año 2008 y la columna de la derecha representa las rosas de viento construidas con direcciones del viento de todos los años disponibles (1999-2008).

La Tabla 12.3 contiene los coeficientes de correlación $Rws\theta_{i,j}$ entre las velocidades del viento *ws* de la estación candidata *i* y las direcciones del viento θ de la estación de referencia *j*. Para calcular la correlación entre una variable lineal (velocidad del viento) y una variable angular (dirección del viento) se ha hecho uso de la expresión propuesta por Mardia [201], Ec 12-3.

$$\text{(Ec 12-3)} \quad R^2_{ws,\theta} = \frac{r^2_{ws,c} + r^2_{ws,s} - 2r_{ws,c}r_{ws,s}r_{c,s}}{1 - r^2_{c,s}}$$

Donde $r_{ws,c}$, $r_{ws,s}$ y $r_{c,s}$ vienen dados por Ec 12-4.

$$\text{(Ec 12-4)} \quad r_{ws,c} = corr(ws, \cos\theta) \;\; ; \;\; r_{ws,s} = corr(ws, \sin\theta) \;\; ; \;\; r_{c,s} = corr(\cos\theta, \sin\theta)$$

Tabla 12.3 . Coeficiente de Correlación entre las velocidades medias de la estaciones candidatas y las direcciones medias horarias de la estaciones de referencia.

	Año 2008						Años 1999-2008					
Candidata	Estación de referencia						Estación de referencia					
	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6
WS-1	0.332	0.335	0.342	0.247	0.361	0.486	0.254	0.311	0.282	0.265	0.292	0.454
WS-2	0.270	0.325	0.341	0.220	0.343	0.446	0.280	0.337	0.292	0.268	0.345	0.453
WS-4	0.211	0.443	0.280	0.402	0.198	0.360	0.217	0.389	0.257	0.384	0.203	0.377
WS-5	0.281	0.301	0.272	0.162	0.399	0.314	0.273	0.273	0.238	0.186	0.338	0.324
WS-6	0.163	0.134	0.124	0.179	0.241	0.415	0.199	0.189	0.120	0.124	0.224	0.367

Los modelos de turbinas eólicas utilizados en este estudio (E44, E70) [165], (G52,G58,G80) [166] se han seleccionado de tal forma que se correspondan con diferentes rangos de potencia nominal. Las curvas características potencia-velocidad de dichas turbinas se muestran en la Fig.12.5.

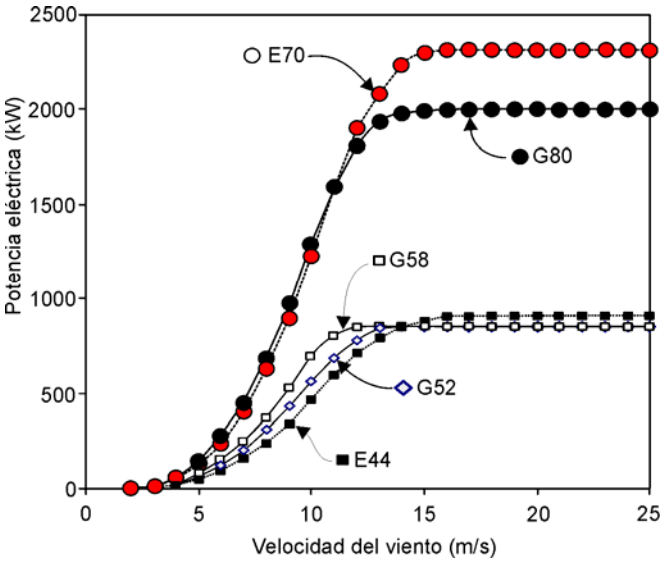

Figura 12.5: Curvas de Potencia de los aerogeneradores utilizados en el estudio del presente capítulo.

12.5 Metodología

Como pasos previos a la estimación del coste específico de la energía eléctrica (c€/ kWh) a largo plazo (long-term) en un sitio candidato, en la metodología desarrollada se estiman las velocidades del viento, las densidades de potencia eólica y las potencias eléctricas en el mismo.

En el proceso de estimación de las velocidades del viento medias horarias a largo plazo en las estaciones candidatas se han utilizado las arquitecturas de ANNs y el VRM anteriormente descritos. Se parte del supuesto de que se dispone de los datos medios horarios de la velocidad y dirección del viento en la estación candidata y en la estación de referencia durante un coincidente corto periodo de tiempo. Como periodo de disposición simultánea de datos en ambas estaciones se ha elegido el año 2008. Asimismo, se parte de la hipótesis de que se cuenta con las series históricas (largo plazo) de velocidades y direcciones del viento de las estaciones de referencia.

Con los datos de viento del año 2008 se genera el modelo que caracteriza la relación entre la estación candidata y la estación de referencia (etapa representada con el número 1 encerrado en un círculo en la figura 12.6). Alimentando al modelo con las velocidades y direcciones medias horarias conocidas a largo plazo de la estación de referencia, se estiman las

velocidades de viento medias horarias a largo plazo en la estación candidata (etapas representas con los números 2 y 3 encerrados en un círculo en la figura 12.6.

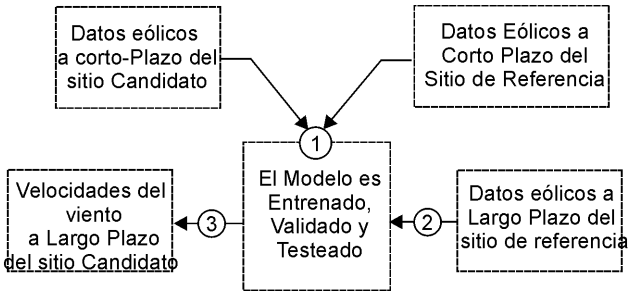

Figura 12.6: Fases del procesos de estimación de la velocidad del viento a largo plazo

En la metodología desarrollada, a partir de las estaciones meteorológicas disponibles se plantean diferentes casos en los que una (o varias en el caso de las ANNs) de dichas estaciones se toma de referencia y otra como candidata.

Con el propósito de comparar los resultados obtenidos con el VRM y las ANNs propuestas se analizan dos escenarios:

A) Las ANNs utilizan una única estación de referencia, al igual que el VRM.
B) Las ANNs utilizan dos estaciones de referencia, mientras que el VRM utiliza una única estación de referencia.

12.5.1 Escenario A

En el escenario que se ha denominado A se han analizado los quince casos indicados en la Tabla 12.4.

Tabla 12.4 Casos estudiados en los escenarios A y B

	Escenario A		**Escenario B**	
Número del caso	**Estación eólica de Referencia**	**Estación eólica Candidata**	**Estación eólica de Referencia**	**Estación eólica Candidata**
1	WS-1	WS-2	WS-1 ; WS-3	WS-2
2	WS-1	WS-3	WS-1 ; WS-2	WS-3
3	WS-1	WS-4	WS-1 ; WS-2	WS-4
4	WS-1	WS-5	WS-1 ; WS-3	WS-5
5	WS-1	WS-6	WS-1 ; WS-5	WS-6
6	WS-2	WS-3	WS-2 ; WS-5	WS-3
7	WS-2	WS-4	WS-2 ; WS-3	WS-4
8	WS-2	WS-5	WS-2 ; WS-6	WS-5
9	WS-2	WS-6	WS-2; WS-4	WS-6
10	WS-3	WS-4	WS-3 ; WS-5	WS-4
11	WS-3	WS-5	WS-3 ; WS-2	WS-5
12	WS-3	WS-6	WS-3 ; WS-1	WS-6
13	WS-4	WS-5	WS-4	WS-5
14	WS-4	WS-6	WS-4	WS-6
15	WS-5	WS-6	WS-5 ; WS-4	WS-6

Las arquitecturas de las ANNs utilizadas en este escenario pueden ser representas por la figura 12.1, en el caso particular de que N sea igual a uno. El número de neuronas de la única capa oculta existente se fijó en quince. Dicho número de neuronas se estableció al comprobar en pruebas previas realizadas que el uso de un número de neuronas superior a quince no proporcionaba una mejora de los resultados e incrementaba el tiempo de entrenamiento de la

red. Con el objeto de evaluar la calidad de los modelos diseñados con las series de datos de viento disponibles en el periodo de corto plazo (año 2008) para las estaciones de referencia y candidata, se han divididos las mismas en tres subconjuntos aleatorios y diferentes de datos: los datos de entrenamiento (training data), los datos de validación (validation data) y los datos de ensayo (test) [164]. La proporción de datos seleccionada para cada uno de los subconjuntos ha sido de 60%, 20% y 20%, respectivamente.

El subconjunto de datos de entrenamiento se utiliza para la estimación de los parámetros de las ANNs. El subconjunto de validación es utilizado para chequear el progreso del entrenamiento de las ANNs, optimizando los parámetros de las mismas. Es decir, se utilizan para medir el grado de generalización de las ANNs. El subconjunto de los datos de ensayo, que no han sido utilizados ni en la etapa de entrenamiento ni de validación, es usado para calcular el porcentaje de error de la red final optimizada. Es decir, constituye una medida independiente del funcionamiento de la red después del entrenamiento. Sin embargo, los modelos utilizados para llevar a cabo la estimación a largo plazo se construyeron utilizando el 100% de los datos disponibles en el periodo de corto plazo. El 80% de dichos datos se utilizaron para el entrenamiento y el 20% restante para la validación.

Los distintos experimentos han sido realizados empleando el algoritmo denominado Trainlm, el cual está disponible en la Toolbox de redes neuronales de MATLAB [169].

Con respecto a los parámetros de los modelos desarrollados en el VRM hay que señalar que en este capítulo estos han sido calculados para doce 30º bines de dirección. Si la Ec 12-2 proporciona valores negativos de la velocidad, entonces se le asigna a dichas velocidades el valor nulo. Para evaluar la calidad de los modelos VRM se llevó a cabo una validación simple [164]. Es decir, se reservó un 20% de los datos como subconjunto de prueba, que no se empleó en la construcción del modelo. El 80% restante se utilizó para el entrenamiento. La división de los datos en estos dos grupos fue aleatoria. Los modelos VRMs utilizados para llevar a cabo la estimación a largo plazo se construyeron utilizando el 100% de los datos disponibles en el periodo de corto plazo. Los distintos experimentos han sido programados empleando el software MATLAB.

12.5.2 Escenario B

En este escenario los modelos de ANNs utilizados pueden ser representados mediante la figura 12.1, en el caso particular de que N sea igual a dos. Los casos analizados en este escenario se muestran en la Tabla 12.4. Puede observarse que estos casos se han obtenido al

añadir a las estaciones de referencia del escenario A (Tabla 12.4) una estación de referencia adicional. La estación añadida se ha seleccionado con el criterio de que fuese la que, después de la estación de referencia utilizada en el escenario A, poseyera la más alta correlación con la estación candidata (Tabla 12.2).

Hay que señalar que los casos 13 y 14 de este escenario coinciden con los correspondientes del escenario A, ya que no existe una segunda estación que tenga un coeficiente de correlación inferior al que poseen la estación WS-4 con las WS-5 y WS-6 (Tabla 12.2)

12.6 Parámetros analizados

Los parámetros analizados en este capítulo son las velocidades del viento, las densidades de potencia eólica, las potencias eléctricas generadas por una turbina eólica y los costes específicos de la energía eléctrica (c€/ kWh) estimados a largo plazo en los sitios candidatos.

12.6.1 Velocidad del viento

Tanto al usar los modelos de ANNs como los VRMs se han analizado los errores producidos al estimar las *n* velocidades medias horarias del viento generadas por los mismos. Es decir, para las ANNs se han analizado los errores producidos entre las velocidades del viento estimadas con las arquitecturas representadas con la figura 12.1 (casos N=1 y N=2) y por los modelos VRM representados por la Ec 12-2.

12.6.2 Densidad de la potencia eólica

La densidad de potencia eólica, P_i, o potencia por unidad de área perpendicular a la dirección del viento, viene dado por Ec 12-5, [7,141,193-194,196]

(Ec 12-5) $$P_i = \frac{1}{2}\rho_i v_i^3$$

En Ec 12-5, si ρ_i está expresada en kg m^{-3} y v_i en m s^{-1}, P_i se obtendrá en W m^{-2}. P_i, que depende de la densidad del aire ρ_i y de la velocidad del viento v_i , es la unidad básica para medir la potencia contenida en el viento. Como se señala en [141], la densidad del aire es una variable continua que depende de la presión, las temperatura y la humedad. Sin embargo, en la

literatura científica se asume que la densidad del aire es constante. El valor típico utilizado para la en toda la literatura consultada es ρ =1.225 kgm^{-3}. Este valor se corresponde con las condiciones estándares (emplazamiento a nivel del mar,15 ºC). Con esta consideración, se analizan en este capítulo los errores producidos al estimar las *n* densidades de potencia eólica medias horarias del viento generadas en los distintos casos por los diferentes modelos utilizados.

12.6.3 Potencia eléctrica

Para estimar las potencias eléctricas generadas por las turbinas eólicas seleccionadas para este estudio se han utilizado las curvas de potencia-velocidad del viento características de las mismas (Fig.12.5) [165-166]. Los fabricantes suelen suministrar las curva de potencia de los aerogeneradores en forma discreta, con k-nodos (Pwt_j, V_j). La potencia eléctrica obtenible entre dos nodos ‘‘j” and ‘‘j + 1” de la curva de potencia puede calcularse de forma aproximada [90]. Una de las posibles formas de aproximación consiste en asumir que la variación entre dos nodos de la curva de potencia es lineal, (Ec 12-6).

(Ec 12-6)
$$PWT(v_i) = \begin{cases} \dfrac{Pwt_{j+1} - Pwt_j}{V_{j+1} - V_j}(v_i - V_j) + Pwt_j & 1 \le j \le K-1 \\ 0 \quad ; \quad V_{cut\text{-}out} < v_i < V_{cut-in} \end{cases}$$

Donde $V_{cut\text{-}in}$ y $V_{cut\text{-}out}$ son las velocidades de arranque y parada, respectivamente, de la turbina eólica. Hay que señalar que las velocidades de viento utilizadas en la Ec 12-6 son las estimadas en la estación objetivo a la altura de las estaciones utilizadas. Es decir, a 10 metros sobre el nivel del suelo. Ello, se ha realizado así con el propósito de no introducir los errores que se generan con los modelos de extrapolación de la velocidad del viento con la altura.

12.6.4 Coste de la energía eléctrica

En la literatura científica relacionada con las energías renovables se han propuesto diferentes métodos de análisis económico [7,193-197]. En este capítulo se ha elegido un modelo simplificado de cálculo del coste específico de la energía, *COE*. Dicho método, similar al método EPRI TAG [7,193,194] estima el coste como el ratio entre los costes totales y la energía eléctrica anual producida por el sistema eólico, E_a. En general, en el coste total producido por

una turbina eólica se pueden diferenciar dos términos: uno que depende del coste inicial de la instalación C_I y el otro del coste anual de operación y mantenimiento $C_{O\&M}$, Ec 12-7

$$\text{(Ec 12-7)} \quad COE = \frac{C_I \cdot FCR + C_{O\&M}}{E_a} = \frac{C_I \cdot FCR}{E_a} + c_{O\&M} = c_I + c_{O\&M}$$

En la Ec 12-7 *FCR* es un ratio de aplicación anual sobre la inversión (en inglés, fixed charge rate per year) y su valor en este capítulo es de 0.05.

Para el cálculo de C_I se ha supuesto una inversión específica de 1200€ por kW instalado. Este valor se extrae de la experiencia de los autores en este tipo de instalaciones en las Islas Canarias. $C_{O\&M}$, recoge los costes operación y mantenimiento preventivo y correctivo, los costes de arrendamiento de terrenos, gastos de administración, etc. En el Archipiélago Canario, según la experiencia de los autores de este capítulo, el coste específico de operación y mantenimiento anual, $c_{O\&M}$, puede estimarse en 1,6c€/kWh.

La Ec 12-7 asume que el periodo de endeudamiento es igual a la vida de la turbina eólica. En este trabajo el periodo de vida se ha estimado en veinte años, el cual es el que generalmente de garantiza por parte de los fabricantes.

12.7 Métricas utilizadas en la evaluación numérica de los resultados.

Entre las diversas alternativas que han sido propuestas [164,202] para evaluar numéricamente las estimaciones realizadas por los modelos, en este capítulo se han seleccionado dos para analizar la estimación de los parámetros descritos en el apartado 12.6. Estas han sido, el denominado Error Absoluto porcentual medio (en inglés, Mean Absolute Percentage Error – MAPE- y el coeficiente de correlación R.

El MAPE ha sido utilizado por diversos autores con anterioridad [22,25] y, generalmente, se expresa por la Ec 12-8

$$\text{(Ec 12-8)} \quad MAPE = \frac{100}{n} \sum_{i=1}^{n} \frac{|O_i - E_i|}{O_i}$$

R, Ec 12-9, mide la correlación estadística existente entre los datos medidos u observados y los datos estimados. El coeficiente de correlación varía entre 1 y -1. Toma el valor 1 para

resultados perfectamente correlacionados y 0 cuando no existe relación. Los valores negativos indican la existencia de una correlación negativa [164].

(Ec 12-9) $$R = \frac{\sum_{i=1}^{n}\left(E_i - \overline{E}\right)\left(O_i - \overline{O}\right)}{\sqrt{\left[\sum_{i=1}^{n}(E_i - \overline{E})^2\right]\left[\sum_{i=1}^{n}(O_i - \overline{O})^2\right]}}$$

En las Ec 12-8 y Ec 12-9, n es el número de datos analizados, O_i son los datos medidos u observados, E_i son los valores estimados, $\overline{O}$ y $\overline{E}$ son las medias de los valores O_i y E_i, respectivamente.

12.8 Análisis de los resultados

En la figura 12.7 se muestran los MAPEs obtenidos al estimar las velocidades medias horarias del viento a largo plazo en los quince casos analizados, tanto en el escenario A como en el B (Tabla 12.4). Es decir, se muestran los MAPEs generados cuando se ha hecho uso del VRM y de las arquitecturas de ANNs. Respecto de estas últimas, se muestran los errores de las arquitecturas que utilizan como señales de entradas las velocidades y direcciones medias horarias del viento procedentes tanto de una única estación de referencia (escenario A), como de dos estaciones de referencia (escenario B). Asimismo, se han representado en la figura 12.7 los MAPEs generados cuando los datos de viento del periodo de corto plazo (año 2008) se han considerado representativos del periodo de largo plazo. Puede observarse en la figura 12.7 que los modelos desarrollados haciendo uso de los VRMs son los que han generado mayores MAPEs. Con excepción de los casos 12 y 15, donde los resultados son similares, existen casos donde el MAPE obtenido con las ANNs del escenario A se ha logrado reducir sustancialmente respecto del producido por el VRM. Concretamente, el MAPE del caso 4 se ha reducido un 28,7%. Es decir, se ha pasado de un MAPE del 49,61% (VRM) a uno del 35,35% (ANN).

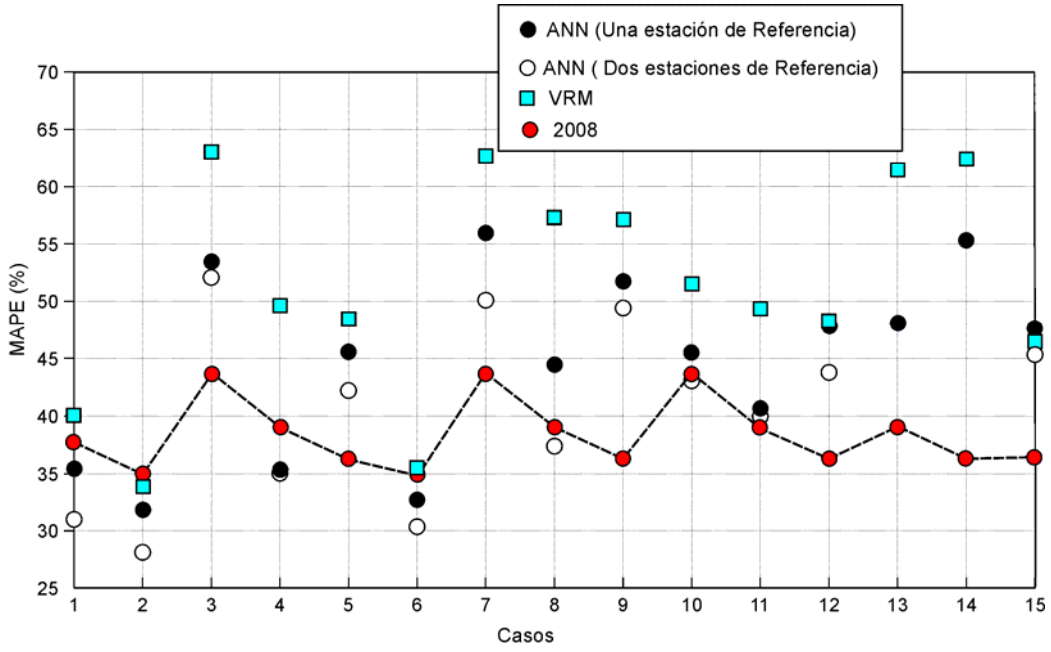

Figura 12.7: MAPEs obtenidos al estimar las velocidades medias horarias del viento a largo plazo en los quince casos analizados.

En el mismo sentido, se muestran los resultados para el coeficiente de correlación R (Fig.12.8). En la figura 12.8 se pueden comparar los resultados obtenidos con ambos métodos. Asimismo, se muestra en dicha figura el coeficiente de correlación calculado entre las velocidades medias horarias del viento de la estación candidata y de referencia en el periodo de corto plazo (Tabla 12.2). Puede observarse que los Rs obtenidos con las ANNs entre los valores estimados y medidos a largo plazo en la estación candidata son más altos que los Rs medidos durante el periodo de corto plazo entre las estaciones de referencia y candidatas (2008).

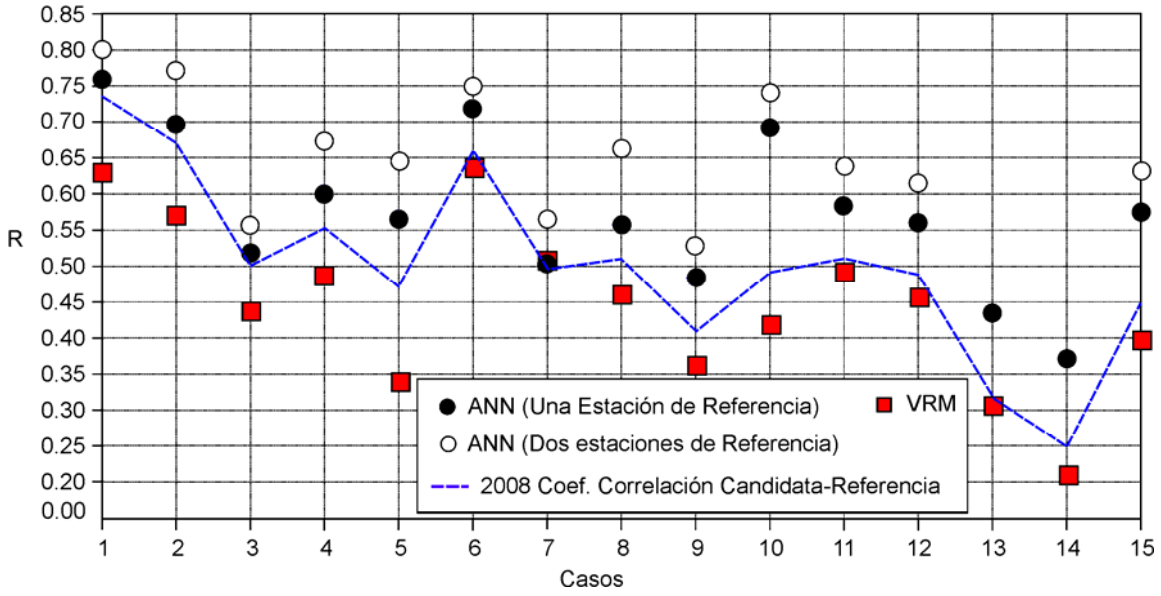

Figura 12.8: Coeficientes de correlación obtenidos al estimar las velocidades medias horarias del viento a largo plazo en los quince casos analizados.

Asimismo, puede comprobarse en las figuras 12.7 y 12.8 que las ANNs del escenario B han producido, en todos los casos analizados, menores MAPEs y mayores Rs que las ANNs del escenario A. Es decir, que el uso de una segunda estación de referencia ha mejorado en todos los casos considerados la estimación de las velocidades medias horarias del viento a largo plazo. En la figura 12.9 se muestra en un gráfico de burbujas las diferencias entre los MAPEs generados por las ANNs del escenario A y los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo. Se puede observar que para muy bajos coeficientes de correlación velocidad-velocidad (inferiores a 0.509) los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo han sido inferiores a los obtenidos con todos los métodos de estimación utilizados.

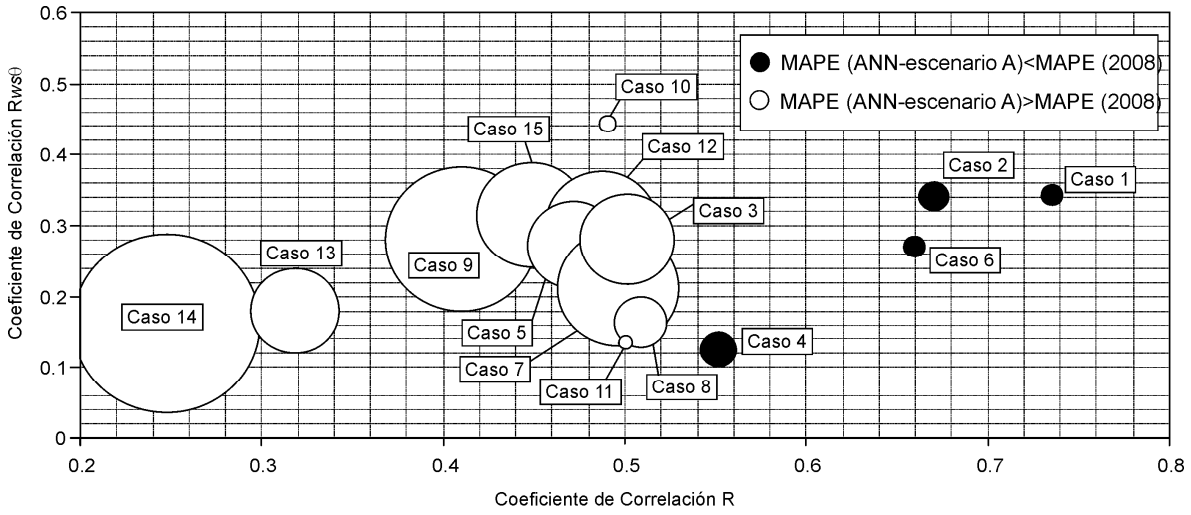

Figura 12.9: Diferencias entre los MAPEs generados por las ANNs del escenario A y los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo.

En la figura 12.10 se representa un diagrama similar al de la figura 12.9, pero en lugar de los MAPEs de las ANNs del escenario A se han utilizado los correspondientes al escenario B. Al comparar las figuras 12.9 y 12.10 se observan dos diferencias. Por un lado, que las ANNs del escenario B incrementan el número de casos en los que los MAPEs generados por los modelos son inferiores a los obtenidos al considerar los datos del año 2008 representativos del comportamiento del viento a largo plazo. Por otro lado, se observa que las diferencias entre los MAPEs generados con los modelos y los MAPEs obtenidos con los datos del 2008 son mayores cuando se utiliza el escenario B que cuando se usa el escenario A. En los casos donde los coeficientes de correlación son muy bajos los métodos utilizados en este capítulo no son una solución adecuada a la hora de estimar las velocidades medias horarias a largo plazo. En estas circunstancias los investigadores pueden obtener mejores estimaciones si confían en los datos medidos durante una año en el sitio candidato en lugar de los resultados que se obtengan de los métodos aquí analizados. Sin embargo, este hecho no ha sido generalmente analizado cuando se han usado datos de estaciones con reducida correlación para diseñar modelos de estimación de los recursos eólicos a largo plazo [9,26].

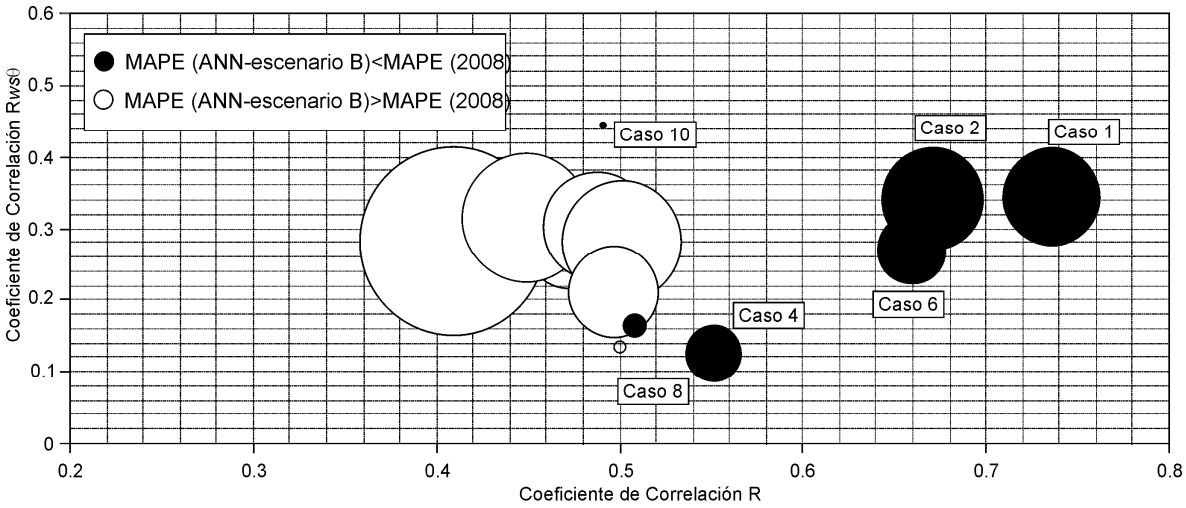

Figura 12.10: Diferencias entre los MAPEs generados por las ANNs del escenario B y los MAPEs obtenidos al considerar que los datos del periodo corto (2008) son representativos del comportamiento del viento a largo plazo.

Asimismo, se observa en la figura 12.7 que los menores errores se producen en los casos 1,2 y 6 (Tabla 12.4). Es decir, en los casos donde los coeficientes de correlación (velocidad-velocidad y velocidad-dirección) calculados en el periodo de corto plazo entre las estaciones candidatas y de referencia son más altos. También puede concluirse del análisis de los resultados representados en la figura 12.7 que los MAPEs obtenidos con los métodos de estimación utilizados son altos. Ello, es consecuencia de los relativamente bajos coeficientes de correlación existentes entre las series de datos de viento de las estaciones de referencia y candidatas (Tabla 12.2).

De forma similar a la representada en la figura 12.7, se muestran en la figura 12.11 los MAPEs obtenidos al estimar las densidades de potencia medias horarias del viento a largo plazo.

Puede observarse en la figura 12.11 que, con excepción del caso 2, los modelos desarrollados haciendo uso de los VRMs, han generado mayores MAPEs que las ANNs del escenario A. Además, puede comprobarse en la figura 12.11 que las ANNs del escenario B han producido en todos los casos analizados menores errores que los modelos que han usado el VRM. Es decir, la inclusión de una segunda estación de referencia ha permitido mejorar las estimaciones de las densidades de potencia eólica medias horarias. Sin embargo, también puede concluirse del análisis de los resultados representados en la figura 12.11 que los MAPEs de este parámetro son muy superiores a los obtenidos en la estimación de las velocidades del viento

(Fig.12.7). Ello se debe a la relación cúbica existente entre las densidades de potencia eólica, Ec 12-3, y las velocidades del viento.

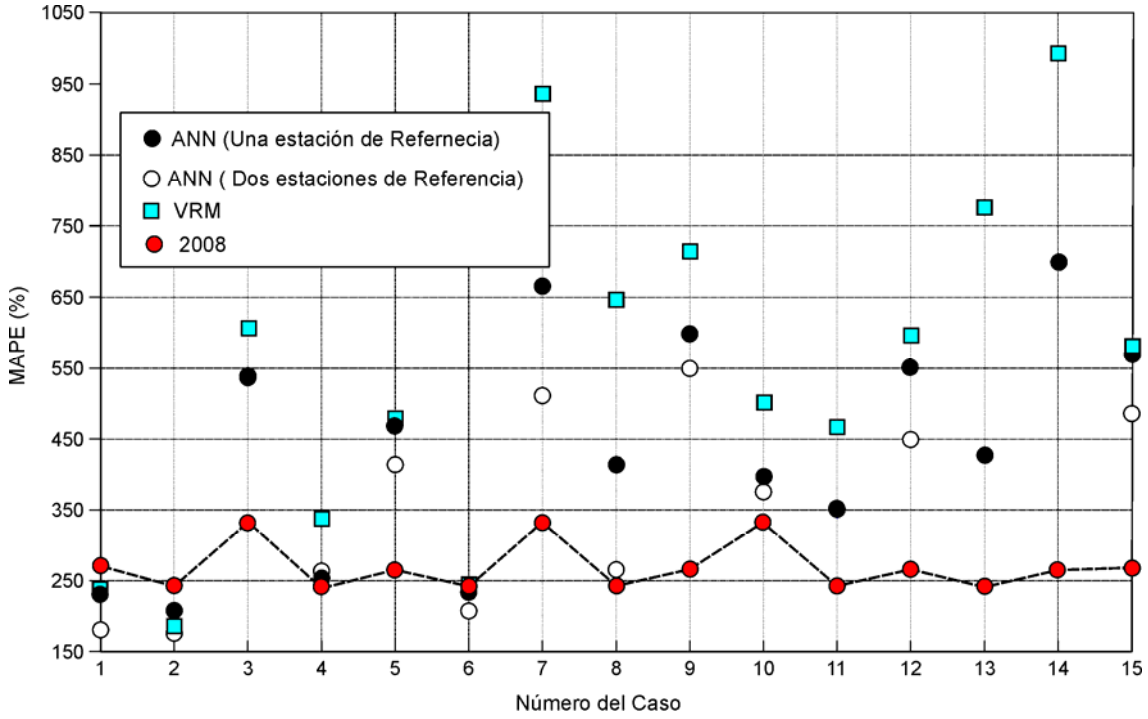

Figura 12.11: MAPEs obtenidos al estimar las densidades de potencia medias horarias del viento a largo plazo en los quince casos analizados.

Puede observarse en la figura 12.11 que solo en los casos 1, 2 y 6, donde los coeficientes de correlación entre las estaciones de referencia y las candidatas son de 0.736, 0.671 y 0.66, respectivamente, los MAPEs obtenidos con las ANNs son inferiores a los obtenidos al considerar que la serie de velocidades y direcciones medias horarias del viento del periodo corto (2008) son representativas del comportamiento del viento a largo plazo. En la figura 12.12 se muestran de similar manera a la reflejada en las figuras 12.7 y 12.11 los MAPEs medios obtenidos al estimar las potencias eléctricas medias horarias generadas por las turbinas eólicas consideradas en este capítulo (Fig.12.5).

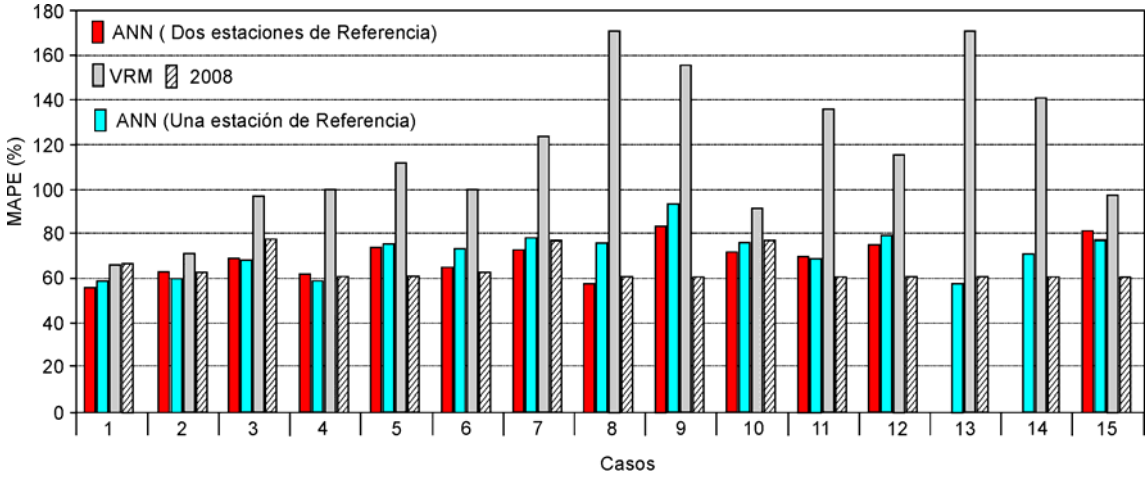

Figura 12.12: MAPEs medios obtenidos al estimar las potencias eléctricas medias horarias generadas por las turbinas eólicas consideradas en este capítulo.

Puede observarse que en todos los casos analizados las ANNs del escenario A han proporcionado menores errores que los obtenidos al hacer uso del VRM. Sin embargo, los menores errores que han generado las ANNs del escenario B frente a los producidos por las ANNs del escenario A en la estimación de la velocidades medias horarias del viento (Fig.12.7) no se han observado en todos los casos analizados cuando se han estimado las potencias eléctricas medias horarias generadas por los aerogeneradores utilizados. En ello, influyen varios factores, que han actuado simultáneamente. Uno de ellos es la pequeña diferencia entre los errores que en algunos casos ha existido entre el escenario B y el A en la estimación de las velocidades medias horarias del viento. Otro factor ha sido la existencia de altos MAPEs y bajos Rs entre las velocidades medias horarias del viento que se han estimado a largo plazo y las realmente observadas. Un tercer factor es consecuencia de las moderadas velocidades del viento existentes, a 10 metros sobre el nivel del suelo, en las estaciones analizadas. Dichas velocidades originan que las turbinas eólicas operen con mayor frecuencia en la zona comprendida entre la velocidad de arranque y la velocidad nominal. Ello, se deduce de las magnitudes que alcanzan en los sitios candidatos los factores de capacidad anuales CF de los aerogeneradores (Fig.12.13).

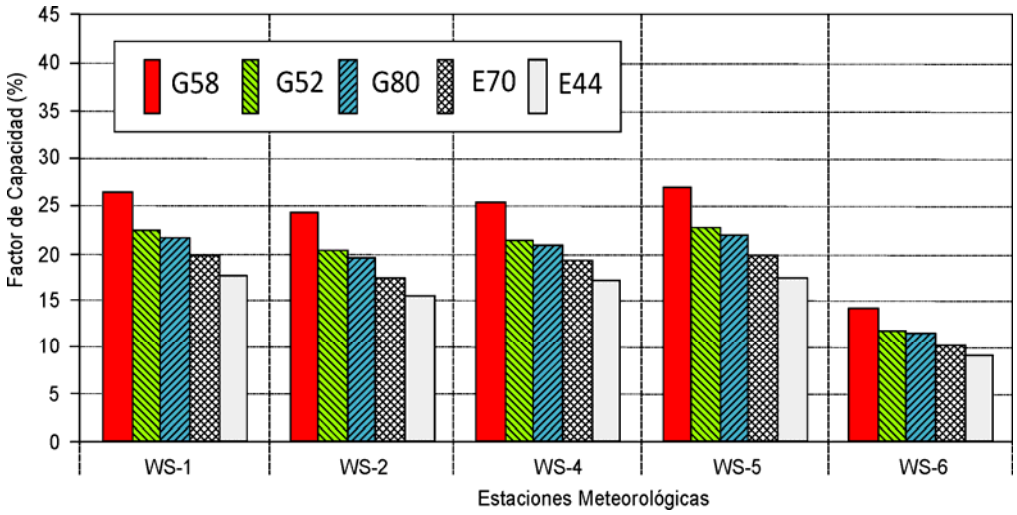

Figura 12.13: Factores de capacidad anuales de los aerogeneradores en las estaciones candidatas.

Puede observarse que los CFs, o ratios entre las potencias medias anuales generadas por los aerogeneradores y las potencias nominales de los mismos [7,193,196], son moderadamente bajos a 10 metros sobre el nivel del suelo. Por tanto, las oscilaciones de potencia eléctrica que se generan en la zona en la que el aerogenerador trabaja a carga parcial influyen más significativamente en el MAPE obtenido al estimar las potencias eléctricas medias horarias generadas por las turbinas eólicas cuanto mayor sea el MAPE de las velocidades medias horarias del viento en dicho margen de operación. Dado que las oscilaciones de potencia generada por un aerogenerador dependen de la forma de la curva de potencia en el rango de velocidades de carga parcial de la misma, los MAPEs obtenidos al estimar las potencias eléctricas medias horarias también dependen de las características de dicha curva. Los menores MAPEs obtenidos en la estimación de las potencias eléctricas medias horarias generadas por los aerogeneradores respecto de los MAPEs producidos en la estimación de las densidades de potencia eólica medias horarias también están relacionados con las características de las curvas de potencia-velocidad del viento de los modelos de aerogeneradores utilizados.

El efecto combinado de los tres factores anteriormente mencionados también ha originado que se eleve hasta ocho el número de casos (casos 1-4,7-8,10 y 13) (Fig.12.12) en los que las ANNs han dado lugar a menores MAPEs que los producidos en la consideración de que la serie de datos del viento del periodo corto (2008) sean representativas del comportamiento del viento a largo plazo. De lo anteriormente expuesto y dado el número reducido de estaciones

analizadas y el limitado rango de coeficientes de correlación disponibles, es difícil proporcionar una guía orientativa de cuanto de bajo ha de ser la magnitud del coeficiente de correlación para que no sea recomendada la utilización de la estación de referencia en la estimación a largo plazo de la energía producida por un aerogenerador dado.

En la figura 12.14 se muestran de similar manera a la reflejada en las figuras 12.7, 12.11 y 12.13, los MAPEs medios obtenidos al estimar los costes específicos de la energía eléctrica generados por los costes de inversión y puesta en marcha (c_I) de las turbinas eólicas consideradas en este capítulo.

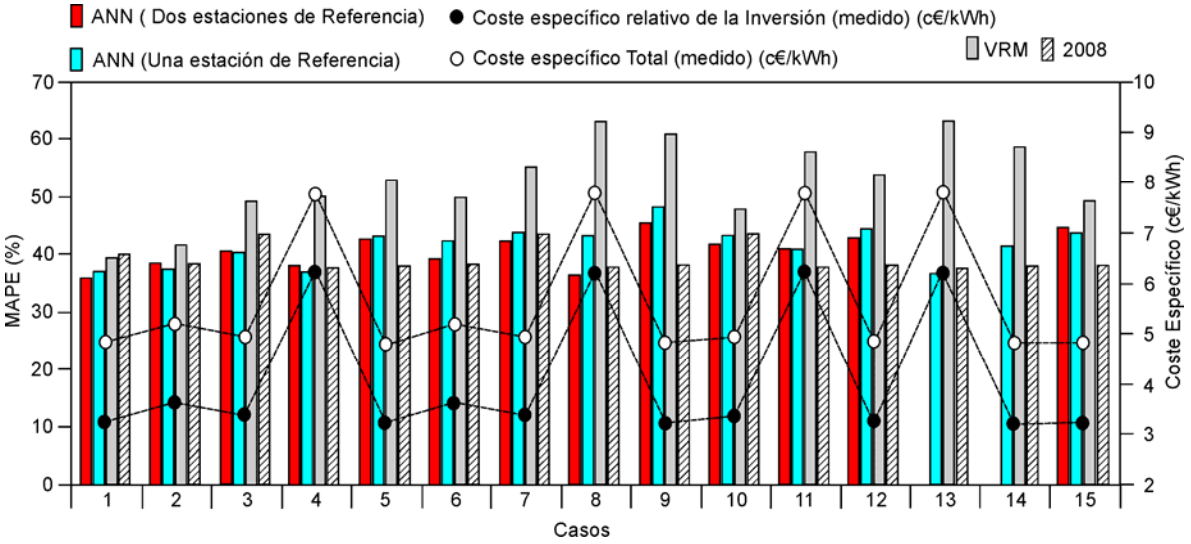

Figura 12.14: MAPEs medios obtenidos al estimar los costes específicos de la energía eléctrica generados por los costes de inversión y puesta en marcha (c_I) de las turbinas eólicas consideradas.

Puede observarse que en todos los casos analizados los errores obtenidos al hacer uso de modelos basados en el VRM son superiores a los obtenidos cuando se han empleado los modelos basados en ANNs. En el escenario A la diferencia de los errores cometidos entre los dos métodos ha oscilado entre un 2,66% del caso 1 y un 26,57% del caso 13. En términos absolutos, y en relación al observado costo específico generado por la inversión (c_I), dichas diferencias de errores equivalen a ±0,085c€/kWh y ±1,647c€/kWh, respectivamente.

En la estimación de este parámetro se ha observado que, de similar manera a la estimación de las potencias eléctricas medias horarias, también han sido ocho los casos (casos 1-4,7-8,10 y 13) (Fig.12.14) en los que las ANNs han dado lugar a menores MAPEs que los producidos en

la consideración de que la serie de datos del viento del periodo corto (2008) sean representativas del comportamiento del viento a largo plazo.

Existe una tendencia de los MAPEs producidos por los modelos VRM y ANNs analizados en este capítulo a decrecer cuando los coeficientes de correlación se incrementan. De los casos analizados se ha observado que solo con coeficientes de correlación de 0.736 (velocidad-velocidad) y 0.342 (velocidad-dirección), medidos entre los datos de viento medios horarios de la estación candidata y de referencia en el periodo corto, todos los parámetros analizados han generado menores MAPEs cuando se han usado las ANNs que cuando se han usado los datos de viento del año 2008 como representativos del largo plazo. Dado el limitado número de estaciones analizadas no se ha podido deducir una regla empírica basada en la magnitud del coeficiente de correlación del periodo de corto plazo que ayude a decidir si es más realista utilizar las ANNs para estimar las potencias eléctricas medias horarias a largo plazo o es mejor confiar en los datos de viento observados en el periodo corto en la estación candidata. Sin embargo, del análisis de los datos utilizados en este capítulo se observa que para que el método MCP lineal genere menores MAPEs que los datos de viento del año 2008 (considerado este como representativo del comportamiento a largo plazo del viento), el grado de correlación entre la estación de referencia y la candidata debe ser más alto que el requerido por las ANNs.

Generalmente, el grado de correlación está relacionado con la distancia existente entre la estación candidata y la de referencia [203-204]. En este capítulo, además de las distancias existentes entre las estaciones utilizadas, la orografía de las islas donde estas están ubicadas también afecta al grado de correlación entre los datos de viento registrados en las mismas. Sin embargo, en cada isla existen zonas donde los coeficientes de correlación entre las velocidades del viento registradas en estaciones instaladas en las mismas y las velocidades de las estaciones usadas en este capítulo son relativamente altos. En muchas de las mencionadas zonas se han obtenidos coeficientes de correlación en el rango de 0.88 a 0.95. Sin embargo, dado que las series temporales de velocidad del viento registradas hasta el momento en dichas estaciones son cortas no hemos podido comprobar el efecto de dichos niveles de correlación en la estimación a largo plazo de los parámetros analizados en este capítulo. Según la referencia [205], como regla general, donde el coeficiente de determinación (cuadrado del coeficiente de correlación de Pearson) de una correlación de la velocidad del viento mensual en todas las direcciones es menor de 0.8, hay una sustancial incertidumbre al usar los datos a largo plazo de la estación de referencia para deducir las condiciones del viento a largo plazo en el sitio candidato. Si se admite esta regla, con el rango de coeficientes de correlación mencionado anteriormente se estima que los modelos de ANNs propuestos proporcionarán

menores errores que los que pudiesen generar al utilizar los datos registrados a corto plazo como representativos del comportamiento del régimen de vientos a largo plazo. Asimismo, ateniéndonos a la mencionada regla y de acuerdo con los resultados obtenidos en este capítulo la incertidumbre de la predicción será menor que la generada por el VRM y no será substancial.

Con objeto de analizar el grado de generalización de los modelos utilizados se han trazado las figuras 12.15 y 12.16. En la figura 12.15 se representan los MAPEs obtenidos entre las velocidades medias horarias del viento estimadas y observadas a largo plazo en función de los MAPEs generados en la etapa de ensayo de los modelos (etapa representada con el número 1 encerrado en un círculo en la figura 12.6). En la figura 12.16 es similar a la figura 12.15, pero referida a los coeficientes de correlación R

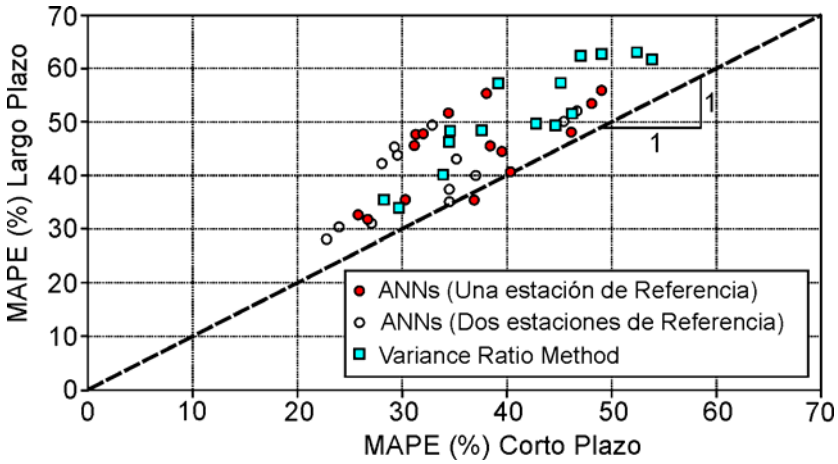

Figura 12.15: MAPEs obtenidos entre las velocidades medias horarias del viento estimadas y observadas a largo plazo en función de los MAPEs generados en la etapa de ensayo de los modelos.

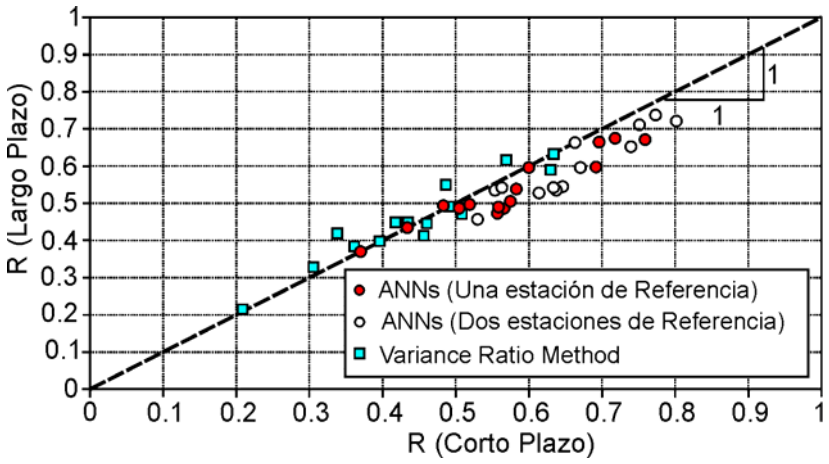

Figura 12.16: Coeficientes de correlación obtenidos entre las velocidades medias horarias del viento estimadas y observadas a largo plazo en función de los coeficientes de correlación generados en la etapa de ensayo de los modelos.

Puede observarse en la figura 12.15 que los MAPEs a largo plazo son algo superiores a los obtenidos en la etapa de ensayo. Asimismo, se observa en la figura 12.16 que los Rs calculados a largo plazo son inferiores a los Rs obtenidos en la etapa de entrenamiento. En ello, influye el grado de representación que los datos de viento del periodo corto tienen de los datos a largo plazo [206] y del nivel de correlación entre las estaciones de referencia y candidata.

12.9 Conclusiones

Del análisis de los resultados alcanzados en este capítulo se obtienen una serie de conclusiones:

a) Los modelos basados en ANNs cuyas señales de entrada son las velocidades y direcciones del viento de una estación de referencia (escenario A) han proporcionado en el 87% de los casos menores MAPEs que los modelos basados en el VRM, al estimar las velocidades medias horarias del viento a largo plazo en las estaciones candidatas.

b) En el 100% de los casos analizados las ANNs del escenario B han generado menores errores que los modelos VRM al estimar las densidades de potencia del viento medias horarias.

c) La inclusión de una segunda estación de referencia en las ANNs (escenario B) ha disminuido en todos los casos analizados los MAPEs obtenidos al estimar, con las ANNs del escenario A, las velocidades del viento y las densidades de potencia del viento a largo plazo.

d) En los casos donde los coeficientes de correlación son muy bajos los métodos utilizados en este capítulo no son una solución adecuada a la hora de estimar las velocidades medias horarias a largo plazo. En estas circunstancias los investigadores pueden obtener mejores estimaciones si confían en los datos medidos durante una año en el sitio candidato en lugar de los resultados que se obtengan de los métodos aquí analizados.

e) En el 100% de los casos analizados, los errores obtenidos en la estimación de los costes específicos de la energía eólica a largo plazo mediante el uso de modelos basados en el VRM han sido superiores a los obtenidos cuando se han empleado los modelos basados en ANNs.

f) Se ha observado que con coeficientes de correlación entre una estación candidata y de referencia de 0.736 (velocidad-velocidad) y 0.342 (velocidad-dirección), todos los parámetros analizados han generado menores MAPEs cuando se han usado las ANNs que cuando se han usado los datos de viento del año 2008 como representativos del largo plazo. Sin embargo, no se ha podido establecer una regla empírica basada en la magnitud de dichos coeficientes debido al reducido número de estaciones analizadas y el limitado rango de coeficientes de correlación disponibles.

g) Existen estaciones ubicadas en zonas de cada isla con registros cortos de datos de viento en las que los coeficientes de correlación con las series de datos de las estaciones consideradas en este capítulo son altos. Si se cumple la regla señalada por la referencia [205], la incertidumbre de la estimación no será sustancial. Además, de acuerdo con los resultados obtenidos en este capítulo, se prevé que la incertidumbre será menor que la producida por el VRM. Asimismo, se estima que las ANNs propuestas generarán menores errores que los pudiesen producir los datos registrados a corto plazo como representativos del régimen de vientos a largo plazo.

CAPITULO 13

Conclusiones de la tesis y Líneas de Investigación Futuras que se Proponen

INDICE

13 CONCLUSIONES DE LA TESIS Y LINEAS DE INVESTIGACION FUTURAS QUE SE PROPONEN 309
13.1 Introducción 309
13.2 Aportaciones de la tesis 310
13.3 Conclusiones 313
13.4 Líneas de investigación futuras que se proponen 316

13 CONCLUSIONES DE LA TESIS Y LINEAS DE INVESTIGACION FUTURAS QUE SE PROPONEN

13.1 Introducción

Cabe volver a recordar en este apartado la justificación de la idea del presente trabajo de investigación.

Cada vez más se hace necesario el diversificar las fuentes energéticas para la generación de energía eléctrica. Si bien a nivel nacional la diversificación en las fuentes energéticas para la generación de energía eléctrica puede ser importante (Figura 8.2), en las islas canarias el efecto no es el mismo. La dependencia del mix energético canario de las fuentes energéticas derivadas del petróleo es muy elevada (Figura 8.3).

Los objetivos estratégicos que en el sector energético se han marcado tanto a nivel europeo, nacional y en concreto para las islas canarias, hacen hincapié en conseguir una importante contribución de las energías renovables a la demanda de energía eléctrica (Ver punto 8.3).

El aislamiento que presentan los sistemas eléctricos en el archipiélago canario, cada isla posee su propio sistema eléctrico aislado de los demás, a excepción de las islas de Lanzarote y Fuerteventura que están interconectadas, y además aislados del sistema eléctrico nacional, trae como consecuencia que éstos sean sensibles (débiles) y limitados.

Por otro lado, la segregación geográfica del archipiélago canario, constituida por islas, y la importancia de la variable medioambiental que hoy forma parte íntima de su cultura, hace que el uso del territorio sea limitado y esté controlado.

Los sistemas de aprovechamiento de la energía eólica como recurso para la generación de energía eléctrica que contribuyen a la diversificación del mix energético canario, son sistemas que requieren grandes superficies de terreno e inversiones económicas elevadas. Este hecho hace que se deba planificar su instalación en el territorio canario de tal forma que se ordenen en zonas que haga compatible su uso con el del resto del territorio. Por otro lado, las áreas que se reserven para su aprovechamiento deben tener el suficiente potencial eólico como para rentabilizar las altas inversiones económicas necesarias. Por todo ello, un exhaustivo análisis del recurso eólico es fundamental en la planificación territorial a la hora de delimitar áreas de ubicación candidatas, y en la toma de decisiones finales para la ejecución de dichas instalaciones eólicas, desde el punto de vista de su rentabilidad económico-financiera.

Para obtener una estimación lo más exacta posible de la producción energética media anual, durante la vida útil de una instalación eólica a instalar en un emplazamiento candidato, se

requiere, debido a la variabilidad interanual de la velocidad del viento, del conocimiento de la evolución de las velocidades a largo plazo en dicha zona [6]. Es decir, se precisa disponer de un análisis del recurso eólico a largo plazo.

Para solventar el problema que se plantea cuando se disponen de periodos cortos (un año) de registro de datos de viento y se desea estimar con cierta garantía cual será el comportamiento medio interanual, se han propuesto en la literatura científica diversos métodos. Éstos intentan extrapolar los datos medidos para estimar los datos desconocidos y eliminar las incertidumbres en la evaluación de la potencia del viento en una localización, debido a la variabilidad del clima local.

En la presente tesis se han desarrollado nuevos métodos de estimación de la potencia eólica a largo plazo utilizando técnicas funcionales y de Aprendizaje Artificial (Machine Learning). Estos métodos se han comparado con los existentes y se han analizado los resultados.

En los apartados siguientes se exponen las aportaciones de la tesis, las conclusiones más sobresalientes que se han obtenido y se proponen líneas de investigación que se derivan de los trabajos desarrollados en el presente trabajo.

13.2 Aportaciones de la tesis

A continuación se expone un listado de las distintas aportaciones de los trabajos desarrollados en la presente tesis:

- Los resultados que se han obtenido en los diferentes estudios realizados en la presente tesis se basan en una información meteorológica fiable aportada por entidades de reconocido prestigio en el ámbito del tratamiento de información meteorológica. Las fuentes de la información han sido el Instituto Tecnológico de Canarias, empresa perteneciente al Gobierno de Canarias y la Agencia Estatal de Meteorología del Ministerio de Medio Ambiente, y Medio Rural y Marino del Gobierno de España.

  En total, en los diversos estudios se ha trabajado con cuarenta estaciones meteorológicas de las que se dispone de las velocidades y direcciones medias horarias. El número de datos totales con los que se trabajado son 2.698.080 datos (que incluyen las velocidades y direcciones del viento).

- Generación de modelos utilizando las Redes Neuronales Artificiales para la estimación de la potencia eólica en la cual se han utilizado la velocidad (V) y la dirección del viento (D), en forma angular, como parámetros en la capa de entrada a la red.

  En la gran mayoría de los estudios científico realizados hasta el momento solamente se usan como señales de la capa de entrada las velocidades de viento registradas en estaciones de referencia seleccionadas. Es decir, ignoran la influencia que puede tener la dirección del viento de las estaciones de referencia en la estimación de las velocidades del viento de la estación candidata

  En uno de los trabajos de investigación realizados hasta el momento [26], se estudia la influencia de la dirección del viento, en magnitud angular, en la estimación de la velocidad del viento en terrenos complejos. Sin embargo, de las cinco estaciones anemométricas utilizadas en dicho estudio, siempre se utiliza la misma estación objetivo y los coeficientes de correlación entre estaciones son del mismo orden. En la presente tesis se ha estudiado este caso mediante el empleo de 22 estaciones diferentes, cada una de las cuales han podido ser seleccionada como de referencia o candidata. De las diferentes combinaciones posibles se han generado los modelos correspondientes a 175 casos que presentan un amplio abanico de coeficientes de correlación entre la velocidad del viento de las estaciones de referencia y candidata (Figuras 9.8 y 9.9).
- Generación de modelos para la estimación de la potencia eólica mediante el empleo de Redes Neuronales utilizando como parámetros en las capas de entrada y salida la velocidad del viento en sus correspondientes componentes cartesianas (V_x, Vy). Comparación de los resultados obtenidos en este caso con los correspondiente al caso donde el parámetro dirección se introduce en la capa de entrada en forma angular (Figuras 9.10 y 9.11).

  Este análisis no se ha realizado en los estudios científicos existentes.
- Valoración de la bondad de la estimación de la velocidad del viento en función de la correlación existente entre las velocidades de las estaciones de referencia y candidata.
- Análisis de la influencia de la incorporación de una estación adicional a la capa de entrada de la red neuronal en la bondad de la estimación de la velocidad del viento.
- Análisis de la influencia de la incorporación de múltiples (más de dos) estaciones de referencia en la capa de entrada de la red neuronal, en la bondad de la estimación de la velocidad del viento, potencia eólica y potencia eléctrica generada por un aerogenerador.

- Realización de un análisis comparativo entre el método de las Redes Neuronales Artificiales y los tradicionales algoritmos MCP (Measure-Correlate-Predict) en la estimación a largo plazo de la velocidad del viento, potencia eólica y potencia eléctrica generada por un aerogenerador.
- Realización de una comparación entre los resultados obtenidos en la estimación a largo plazo de la velocidad, potencia eólica y potencia eléctrica mediante el empleo de las Redes Neuronales y los datos observados a corto plazo como representativos del largo plazo.
- Estimación de la rentabilidad económica de una instalación eólica en términos de la estimación de su coste específico del kWh eléctrico generado por un aerogenerador. Análisis comparativo entre los métodos de las Redes Neuronales y MCP.
- Se ha propuesto un método de estimación de los parámetro eólicos (velocidad, potencia eólica y potencia eléctrica) mediante la utilización de las Redes Bayesianas. Estos métodos no han sido utilizados para la estimación de la velocidad del viento.

  Es un sistema inteligente, cuya base de conocimiento es una función de probabilidad conjunta de todas las variables del modelo, que emplea técnicas eficientes del cálculo de probabilidades condicionadas para realizar el razonamiento. Ello permite realizar de forma eficiente el aprendizaje automático del modelo y la inferencia a partir de la evidencia disponible.
- Se propone un nuevo método probabilístico de Measure-Correlate-Predict (MCP) para estimar las características de la velocidad del viento a largo plazo (long-term) en un emplazamiento candidato. El método que se propone utiliza la función de densidad de probabilidad de la velocidad del viento en el sitio candidato condicionada a la velocidad del viento en el sitio de referencia. Para ello se han utilizado distribuciones bivariables del tipo contingencia (en su traducción al inglés, Contingency-type bivariate distributions) con distribuciones marginales especificadas [140-141].

13.3 *Conclusiones*

En este apartado del capítulo se exponen las conclusiones más sobresalientes que se han obtenido.

- Cuando se aplican las Redes Neuronales en la estimación del recurso eólico, los resultados obtenidos para las métricas mejoran cuanto mayor es el coeficiente de correlación lineal entre las velocidades de la estación de referencia original y la candidata. Para valores del coeficiente de correlación superior a 0.9, el error absoluto relativo medio es inferior a 0.2 (Figura 9.9)
- En la estimación del recurso eólico, cuando se ha utilizado la dirección del viento en magnitud angular como señal de entrada de las ANNs, las métricas obtenidas presentan mejores resultados que los obtenidos cuando dicha señal de dirección es obviada. La disminución de los errores en la estimación pueden ser apreciables, fundamentalmente cuando los coeficientes de correlación lineal existentes entre las velocidades de la estación candidata y las de referencia son inferiores a 0.8.
- Para valores del coeficiente de correlación entre las velocidades de la estación de referencia y candidata comprendidos entre 0.6 y 0.9, los modelos que descomponen la velocidad en sus componentes cartesianas presentan, en la mayoría de los casos, peores métricas que los modelos que usan la dirección del viento en magnitud angular como señal de entrada en la red neuronal.
- Los errores de estimación tienden a disminuir al incrementarse el número de estaciones de referencia utilizadas. Sin embargo, no todas las estaciones de referencia añadidas mejoran los resultados. Por tanto, se propone que se realicen gráficas como las indicadas en la Figura 9.15 al objeto de determinar las estaciones de referencia que proporcionan el mínimo error de estimación
- La mejora que experimentan los resultados al añadir una estación adicional a la capa de entrada de la red neuronal, es independiente del coeficiente de correlación entre las velocidades de la nueva estación de referencia y la estación candidata (Figuras 9.12 y 9.13)
- Si se utilizan señales de entrada de velocidad y dirección angular del viento, el número de estaciones de referencia que se precisan para lograr una cierta magnitud de la

métrica, es inferior al número de estaciones que se requieren si las señales de entrada son solo de velocidad del viento (Figura 9-16).

- El método de las Redes Bayesianas (BN) propuesto en la presente tesis (capítulo 10) supone una alternativa a los modelos MCP que emplean regresiones lineales para relacionar las velocidades del viento entre una estación candidata y una estación de referencia.
- En los casos analizados en el capítulo 10, los modelos obtenidos al aplicar las Redes Bayesianas (BNs) con tres (BN-3) y dos (BN-2) estaciones de referencia han proporcionado menores errores que los MCP de referencia utilizados, independientemente de la métrica utilizada en la estimación de los histogramas de frecuencia acumulada del viento a largo plazo.
- Los modelos BN-3 y BN-2 obtenidos al aplicar las redes bayesianas (BN) presentan un gran poder de generalización. Los errores obtenidos en la etapa de entrenamiento son muy parecidos a los errores cometidos en la predicción a largo plazo.
- Los modelos de Redes Bayesianas con tres estaciones de referencia (BN-3) han presentado en todas las estaciones, una mejor predicción de la potencia eléctrica media extraíble del viento con las dos turbinas eólicas seleccionadas, que los restantes modelos utilizados
- El nuevo método probabilístico MCP propuesto en el capítulo 11 de la presente tesis ha estimado mejor las distribuciones de la velocidad del viento, en la mayoría de los casos analizados, que los restantes métodos que se han empleado en la comparación.
- El algoritmo para la estimación de las características eólica a largo plazo usando, Joint Probabilistic Approach (JPA), que se propone en la literatura científica [16], es el único método que en la estimación de la distribución de la densidad de potencia eólica presenta unos porcentajes de casos ligeramente superiores al método propuesto.
- Como todos los métodos MCP, el método propuesto es vulnerable a los cambios climáticos [192], a la limitada dependencia entre los datos de la estación de referencia y la candidata y a la escasa representación de las características del viento a largo plazo del periodo de datos usado para el entrenamiento.
- Los modelos basados en ANNs cuyas señales de entrada son las velocidades y direcciones del viento de una estación de referencia (escenario A , capítulo 12) han proporcionado en el 87% de los casos menores MAPEs que los modelos obtenidos basados en el VRM (Variance Ratio Method, perteneciente a los métodos de algoritmos

MCP), al estimar las velocidades medias horarias del viento a largo plazo en las estaciones candidatas.

- En el 100% de los casos analizados las ANNs, cuando utilizan dos estaciones meteorológicas en la capa de entrada, han generado menores errores que los modelos VRM al estimar las densidades de potencia del viento medias horarias.
- En los casos donde los coeficientes de correlación son muy bajos, inferiores a 0.509, para los casos analizados en el capítulo 12 del presente trabajo de investigación, los métodos utilizados en el mencionado capítulo no son una solución adecuada a la hora de estimar las velocidades medias horarias a largo plazo. En estas circunstancias se pueden obtener mejores estimaciones si se confía en los datos medidos durante un año en el sitio candidato como representativos de los datos a largo plazo.
- Por otro lado, se ha observado que con coeficientes de correlación entre una estación candidata y de referencia de 0.736 (velocidad-velocidad) y 0.342 (velocidad-dirección), todos los parámetros analizados han generado menores MAPEs cuando se han usado las ANNs que cuando se han usado los datos de viento del año 2008 como representativos del largo plazo.
- En el 100% de los casos analizados, los errores obtenidos en la estimación de los costes específicos de la energía eléctrica de origen eólico a largo plazo mediante el uso de modelos basados en el VRM (método de algoritmo MCP) han sido superiores a los obtenidos cuando se han empleado los modelos basados en ANNs.

13.4 *Líneas de investigación futuras que se proponen*

Durante el trabajo de investigación realizado en la presente tesis han surgido diversas incógnitas, muchas de las cuales han sido resuelta en el mismo trabajo y otras, por razones obvias del propio acotamiento impuesto por los objetivos iniciales marcados en la tesis, se considera oportuno proponerlas como líneas futuras de investigación.
En este apartado se pretende enumerar dichos trabajos de investigación:

- Aplicación de las técnicas estadísticas de Machine Learning para la predicción futura de la velocidad del viento a muy corto plazo (menos de 48 horas).
- Aplicación de las técnicas de estadísticas de Machine Learning para la predicción futura de la potencia eléctrica de un parque eólico a muy corto plazo (menos de 48 horas). Para ello se partiría de los datos de velocidad y dirección predichos y de los históricos de velocidad y producción de los parques eólicos.
- Influencia de la cantidad de información eólica disponible en la estimación de los datos eólicos a corto plazo (un año).

  En muchos ocasiones, la información que se dispone del sitio candidato es inferior a un año. Previo a la estimación de los datos a largo plazo habría que estimar los datos en el corto plazo, un año, a partir de la información que se disponga en las estaciones de Referencia. La cantidad de información disponible en el periodo de medida y su distribución de frecuencias, serán los condicionantes para que la estimación a corto plazo tenga una incertidumbre aceptable.
- Análisis de la influencia del número de datos eólicos de los que se disponga para la fase de entrenamiento del modelo, en relación al número de parámetros de las capas de entrada y salida de las Redes Neuronales, en el rendimiento obtenido, con dicho modelo, en el proceso de estimación de los datos eólicos a largo plazo.

REFERENCIAS BIBLIOGRAFICAS

[1] DIRECTIVA 2009/28/CE DEL PARLAMENTO EUROPEO Y DEL CONSEJO de 23 de abril de 2009 relativa al fomento del uso de energía procedente de fuentes renovables y por la que se modifican y se derogan las Directivas 2001/77/CE y 2003/30/CE: pp L140/16 – L140/62

[2] http://www.cne.es/cne/Home

[3] REAL DECRETO 661/2007, de 25 de mayo, por el que se regula la actividad de producción de energía eléctrica en régimen especial. Mayo 2007, BOE nº 126: pp 22846-22886

[4] P.O. 12.3: Requisitos de respuesta frente a huecos de tensión de las instalaciones eólicas. Octibre 2006, BOE nº 254: pp 3707-37019

[5] Decreto 32/2006, de 27 de marzo, por el que se regula la instalación y explotación de los parques eólicos en el ámbito de la comunidad autónoma de Canarias. Boletín Oficial de Canarias 2006, nº 61: pp 5855-5867.

[6] Hiester TR, Pennell WT. The siting handbook for large wind energy systems. 1st ed. New York: WindBook; 1981.

[7] Spera David A (1995). Wind Turbine Technology. Asme Press.

[8] Corotis RB; Sigl AB; Cohen P (1977). Variance analysis wind characteristics for energy conversion. Journal of Applied Meteorology. Vol. 16. pp. 1149-1157.

[9] Rogers AL, Rogers JW, Manwell JF. Comparison of the performance of four Measure-Correlate-Predict algorithms. Journal of Wind Engineering and Industrial Aerodinamics 2005;93: 243-64.

[10] Clive JM. Non-linearity in MCP with Weibull distributed wind speeds. Wind Engineering 2008;32: 319-24.

[11] Nielsen M, Landberg L, Mortensen NG, Barthelmie RJ, Joensen. A Application of the measure-correlate-predict approach for wind resources assessment. In: Helm P, Zervos A. European wind energy conference. Wind energy for the new millennium, Munich: WIP-Renewable Energies; 2001, p.773-6.

[12] Derrick A. Development of the measure-correlate-predict strategy for site assessment. In: Garrad AD, Palz W, Screller S. European Community wind energy conference, U.K: HS Stephens and Associates; 1993, p.681-5.

[13] Riedel V, Strack M. Robust approximation of functional relationships between meteorological data: alternative measure-correlate-predict algorithms. In: Helm P, Zervos A. European wind energy conference. Wind energy for the new millennium, Munich: WIP-Renewable Energies; 2001, p.806-9.

[14] Woods JC, Watson SJ. A new matrix method of predicting long-term wind roses with MCP. Journal of Wind Engineering and Industrial Aerodynamics 1997; 66:85–94.

[15] Sreevalsan E, Das SS, Sasikumar R, Ramesh MP. Wind Farm Site Assessment Using Measure–Correlate-Predict (MCP) Analysis. Wind Engineering, 2007;31:111-16

[16] García-Rojo R. Algorithm for the estimation of the long-term wind climate at a meteorological mast using a joint probabilistic approach. Wind Engineering 2004;28: 213-24.

[17] Corotis RB; Sigl AB; Cohen P (1977). Variance analysis wind characteristics for energy conversion. Journal of Applied Meteorology. Vol. 16. pp. 1149-1157.

[18] Justus CG, Mani K, Mikhail AS. Interannual and month-to-moth variations of wind speed. Journal of Applied Meteorology 1979; 18:913–20.

[19] Barros V, Estevan E. On the Evaluation of Wind Power from short wind records. Journal of Climate and Applid Meteorology, 1983. Vol 22. pp 1116-1123.

[20] Conrad V, Pollack LW. Methods in climatology. Second ed. Cambridge-Massachusetts: Harvard University Press, 1962.

[21] Oztopal A. Artificial Neural Network approach to spatial estimation of wind velocity. Energy Conversion and Management 2006;47:395–406.

[22] Bilgili M, Sahin B. A. Yasar, Application of artificial neural networks for the wind speed prediction of target station using reference stations data. Renewable Energy 2007;32: 2350–60.

[23] Mabel C, Fernandez E. Analysis of wind power generation and prediction using ANN: A case of study. Renewable Energy 2008;33:986-92.

[24] Monfared M, Rastegar H, Kojabadi HM. A new strategy for wind speed forecasting using artificial intelligent methods. Renewable Energy 2009;34:845-48.

[25] Fadare DA. The application of artificial neural networks to mapping of wind speed profile for energy application in Nigeria. Applied Energy 2010;87:934–42.

[26] López P, Velo R, Maseda F. Effect of direction on wind speed estimation in complex terrain using neural networks. Renewable Energy 2008;33:2266-72.

[27] Kalogirou SA. Artificial neural networks in renewable energy systems applications: a review. Renewable and Sustainable Energy Reviews 2001;5: 373–401.

[28] Neapolitan RE. Learning Bayesian Networks. first ed. New Jersey:Pearson Prentice Hall; 2004.

[28] Barry RG; Chorley RJ (1999). Atmósfera, tiempo y clima. Omega, S.A.

[29] Jarabo Friedrich F; Sanz Martinez de la Peña M; Pérez Dominguez C (1987). *Energías renovables.* Centro de Cultura Popular Canaria. Conserjería de Industria y Energía.

[30] Hidy George M (1968). *Los vientos*. Reveté, S.A.

[31] Barry RG; Chorley RJ (1999). Atmósfera, tiempo y clima. Omega, S.A.

[32] Koeppl Gerald W (1982). *Putnam´s Power From The Wind*. Van Nostrand Rewinhold Company

[33] Le Gouriérès Désiré (1983). *Energía eólica. Teoría, concepción y cálculo práctico de las instalaciones.* Masson., S.A. .

[34] Puig J; Meseguer C; Cabre M (1982). *El poder del viento.* Ecotopia.

[35] Cádiz Deleito JC (1984) *La energía eólica, tecnología e historia.* Hermann Blume

[36] Rodríguez J.L., Burgos J.C., Armatte S., Sistemas eólicos de producción de energía eléctrica. Editorial Rueda, 2003

[37] Ledesma M; Baleriola G (1991). *Meteorología aplicada a la aviación.* Paraninfo.

[38] Hladik Jean (1984). *Énergétique éolienne.* Masson

[39] Justus CG (1980) *Vent et performances des éoliennes.* Ediciones SCM.

[40] Freris LL (1990). *Wind Energy Conversion Systems*. Prentice Hall.

[41] Sathyajitt M., Wind Energy. Fundamentals, Resource Analysis and Economics. Berlin, Heidelberg, 2006 [42] Moses H; Danbek HG (1961). *Errors in wind measurements associated with tower-mounted anemometers.* Bull. Amer. Meteorol. Soc. Vol. 42. pp.190-194.

[43] Dabbert WF (1968). *Tower indiced errors in wind profile measurements.* Journal Applied Meteorology. Vol. 7. pp. 359-359.

[44] Gill GL, Olsson LE; Sela J; Suda M (1967). *Accuracy of wind measurements on towers or stacks.* Bull. Amer. Meteorol. Soc.. Vol. 48. pp. 665-674

[45] UNE-EN 61400-12-1: Medidas de la curva de potencia de aerogeneradores productores de electricidad, Junio 2007.

[46] Burton T; Sharpe D; Jenkins N; Bossanyi E (2001). Wind Energy Handbook. John Wiley & Sons, ltd. pp.617

[47] Canavos George C (1988). *Probabilidad y estadística. Aplicaciones y Métodos*. McGraw-Hill

[48] Peña Sánchez de Rivera D (1995). *Estadística. Modelos y Métodos*. 1. Fundamentos. Alianza Universidad Textos

[49] Johnson N L; Kotz S; Balakrishnan N (1994). *Continuous Univariate Distributions*. Volume 1. John Wiley & Sons,Inc.

[50] Johnson N L; Kotz S; Balakrishnan N (1995). *Continuous Univariate Distributions*. Volume 2. John Wiley & Sons,Inc.

[51] Bury Karl (1999). *Statistical Distributions in Engineering*. Cambridge.

[52] Evans M; Hastings N; Peacock B (1993). *Statistical Distributions*. John Wiley & Sons, Inc.

[53] Stuart A; Ord K (2000). Kendall's Advanced Theory of Statistics. Volume I. Arnold

[54] Carta JA, Ramírez P., Velázquez S. A review of wind speed probability distributions used in wind energy analysis. Case studies in the Canary Islands. Renewable and Sustainable Energy Reviews 13 (2009) 933–955

[55] Takle ES; Brown JM (1978). *Note on the use of weibull to characterize wind speed data.* Journal of Applied Meteorology, Vol. 17, pp. 556-559

[56] Auwera VL; F De Meyer; Malet LM (1980). *The use of the Weibull three parameter for estimating mean wind power densities.* Journal Applied Meteorology. Vol. 19, July, pp. 819-825.

[57] Conradsen K; Nielsen LB; Prahm LP (1984). *Review of Weibull statistics for estimation of wind speed distributions.* Journal of Climate and Applied Meteorology. Vol. 23, August, pp. 1173-1183.

[58] Brett AC; Tuller SE; (1991). *The autocorrelation of hourly wind speed observations*. Journal of Climate and Applied Meteorology. Vol. 30, pp. 823-833

[59] Bayley GV; Hammersly JM (1946). *The 'effective' number of independent observations in an autocorrelated time series*. J Roy Stat Soc. B8. pp. 184-197

[60] Corotis RB (1974). *Statistical analysis of continuous data records.* Journal of the Transportation Engineering Division. American Society of Civil Engineers. Vol. 100. pp. 195-206.

[61] Box GEP; Pierce DA (1970). *Distribution of residual autocorrelations in autoregressive-integrated moving average time series models*. Journal of the American Statistical Association. Vol. 65. pp.1509-1526.

[62] Ljung G; Box GEP (1978). *On a measure of lack of fit in time series models*. Biométrica. Vol. 65. pp. 297-303.

[63] Lobato I.; Nankervis JC; Savin NE (2001). *Testing for autocorrelation using a modified Box-Pierce Q test.* International Economic Review. Vol.42. pp. 187-205

[64] Romero J; Thornbs L (1996). *Inference for autocorretions under weak assumptions.* Journal of The American Statistical Association. Vol. 91. pp. 590-600

[65] Stuart A ; Ord K; Arnold S (1999). Kendall's Advanced Theory of Statistics. Volume 2A. Arnold.

[66] Box GEP; Cox DR (1964). *An analysis of transformations.* J. R. Statist. Soc. Vol. 26. pp.211.

[67] Kirch Allan M (1975). *Estadística con Fortran*. Interamericana

[68] D'Agostino RB; Stephens MA (1986). *Goodness-of-fit techbiques*. Dekker.

[69] Corotis RB; Sigl AB; Klein J (1978). *Probability models of wind velocity magnitude and persistence*. Solar Energy. Vol. 20. pp. 483-493.

[70] Tuller SE; Brett Arthur C (1984). *The characteristics of wind velocity that the fitting of a Weibull distribution in wind speed analysis*. Journal of Climate and Applied Meteorology. Vol. 23, January, pp. 124-134

[71] Öztürk A.; Dale R. (1982). *A study of fitting the Generalized Lambda Distribution to solar radiation data.* Journal of Applied Meteorology. Vol. 21. pp.995-1004

[72] Ramírez P; Carta JA (2005). *Influence of the data sampling interval in the estimation of the Weibull wind speed probability density distribution. A case study*. Energy Conversion and Management. Vol. 46, pp. 2419-2438

[73] García A; Torres, JL; Prieto E; De Francisco A (1998). *Fitting wind speed distributions: A case study.* Solar Energy. 1998. Vol. 62. pp. 139-144

[74] Mann HB; Wald A (1942). *On the choice of the number of intervals in the application of the chi-square test.Ann. Math. Statist. Vol.13, pp. 306-310.*

[75] Schorr B (1974). *On the choice of the class intervals in the application of the chi-square test*. Math. Operations Forsch. Statist. Vol. 5. pp. 357-377.

[76] Press WH; Teukolsky S A; Vetterling WT; Flannery BP (1996) *Numerical recipes in fortran 77.* Cambridge University Press

[77] Draper NR; Smith H (1998). *Applied regression analysis.* John Wiley & Sons, Inc, 1966

[78] Golding E.W. (1980). *The Generation Of Electricity By Wind Power*. E.& F.N. Spon Ltd.

[79] Jones CN (1986). *Notes on the effect of site wind-speed frequency distribution and machine performance characteristics on the annual energy output of a WECS*. Wind Engineering. Vol. 10, No.1 pp. 31-46

[80] Biswas S; Sraedhar BN; Singh YP (1995). *A simplified statistical technique for wind turbine energy output estimation.* Wind Engineering. Vol. 19, No. 3 pp. 147-155.

[81] Gipe Paul (1995) *Wind Energy Comes of Age.* John Wiley & Sons.

[82] Le Gouriérès Désiré (1983). *Energía eólica. Teoría, concepción y cálculo práctico de las instalaciones.* Masson., S.A.

[83] Manwell JF; McGowan JG; Rogers AL (2002). *Wind Energy Explained. Theory, Design and Application*. Wiley.

[84] Eggleston DM; Stoddard F S (1987). *Wind turbine engineering design.* Van Nostrand Reinhold.

[85] Hau E (2000). *Wind Turbines. Fundamentals, Technologies, Applications, Economics.* Springer-Verlag. Berlin

[86] Heier Siegfried (1998). Grid integration of wind energy conversion systems. John Wiley & Sons, Inc.

[87] Carta JA; González J (2001*). Self-sufficient energy supply for isolated communities: wind diesel system in the Canary Islands*. The Energy Journal. Vol. 3, pp.115-145.

[88] Carta J A; González J; Gómez C (2003a*). O perating results of a wind–diesel system which supplies the full energy needs of an isolated village community in the Canary Islands*. Solar Energy. Vol.74, pp.53-63.

[89] Freris LL (1990). *Wind Energy Conversion Systems*. Prentice Hall.

[90] Carta JA., Ramírez P., Velázquez S., Influence of the level of fit of a density probability function to wind-speed data on the WECS mean power output estimation, Energy Conversion and Management 49 (2008) 2647–2655

[91] Jaramillo OA; Borja, MA (2004a). *Wiind speed analysis in La Ventosa,Mexico: a bimodal probability distribution case.* Renewable Energy. Vol. 29. pp. 1613-1630

[92] Jaramillo OA; Borja MA (2004b). Bimodal versus Weibull Wind Speed Distributions: an Analysis of Wind Energy Potential in La Ventosa, Mexico*.* Wind Engineering. Vol.28. pp.225-2234.

[93] García A; Torres, JL; Prieto E; De Francisco A (1998). *Fitting wind speed distributions: A case study.* Solar Energy. 1998. Vol. 62. pp. 139-144

[94] Jamil M. (1994). *Wind power statistics and evaluation of wind energy density.* Wind Engineering. 1994. Vol. 18, No. 5 pp. 227-240

[95] Hussain M; Alam S; Reza KA; Sarkar M (1986). *A study of the wind speed and wind energy availability in Bangladesh.* Energy Conversion and Management; 26:321-7.

[96] Haslett, J; Kelledy E (1981). *A Note on the Use of the Models in the Estimation of Wind Power Avalability*. Wind Engineering.Vol. 5, pp. 6-11

[97] Lysen EH (1983). *Introduction to Wind Energy*. Consultancy Services Wind Energy Developing Countries.

[98] Jones CN. (1988). *The prediction of wind turbine energy output; a brief survey*. Wind Engineering. Vol.12, No.1, pp. 76-87.

[99] Sharaf-Eldeen YI; Moretti PM; Parker JD; Ramakumar RG (1988). *Evaluation of wecs performance and economics in utility interconnected applications.*American Society of

Mechanical Engineers. Conference, Seventh Wind Energy Symposium, New Orleans,LA. pp. 189-193

[100] Sasi KK; Sujay Basu (1997). *On the prediction of capacity factor and selection of size of wind electric generators-a study based on Indian sites.* Wind Engineering. Vol. 21, No. 2 pp. 73-88

[101] Bueno C; Carta JA (2005a*). Technical–economic analysis of wind-powered pumped hydrostorage systems. Part I: model development*. Solar Energy. Vol.78, pp.382-395

[102] Bueno C; Carta JA. (2005b*). Technical–economic analysis of wind-powered pumped hydrostorage systems. Part II: model application to the island of El Hierro*. Solar Energy. Vol. 78, pp.396-405.

[103] Bueno C; Carta JA (2006*).Wind powered pumped hydro storage systems, a means of increasing the penetration of renewable energy in the Canary Islands*. Renewable & Sustainable Energy Reviews. Vol. 10, pp.312-340.

[104] Carta JA; Calero R (1990). Technical-economic optimisation of a desalination system powered by wind energy. In *Proceedings of the European Community Wind Energy Conference,* pp. 596-600, Madrid, Spain.

[105] Carta JA; Calero R (1994) *Aplicación de la energía eólica a la desalación de agua de mar a gran escala.* In *Proceedings of VII Congreso Ibérico de Energía Solar,* pp. 509-514, Vigo, Spain.

[106] Orden de 15 de Noviembre de 2006, por la que se establecen las condiciones técnicos-administrativas para la repotenciación de parques eólicos existentes. Noviembre 2006, BOCA nº 226

[107] Carta JA, Ramírez P, Bueno C. A joint probability density function of wind speed and direction for wind energy analysis. Energy Conversion and Management 2008; 49:1039-20.

[108] Hernández J., Ramírez J.M., Ferri C. Introducción a la minería de datos, 2004: Pearson, D.L. pp 328-352, 2004. ISBN 84-205-4091-9

[109] Acosta M.I., Zuluaga C.A. Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web, 2000

[110] Jud J.S. Neural network design and the complexity of learning, ISBN 0-262-10045-2, 1990

[111] Schuster, H.G., Applications of Neural Networks. ISBN: 3527290109, 1992

[112] Bishop, C.M. Neural networks for pattern recognition, ISBN13: 9780195667998; ISBN10 0195667999, 2009

[113] Matías J.M, Redes Neuronales para regresión y clasificación. Nuevos algoritmos y aplicaciones. ISBN: 84-688-8028-0, 2004

[114] Minsky M., Papert S. Perceptrons. ED MIT, 1969

[115] Rumelhart D. y Zisper D. Feature discover y competitive learning. Cognitive Science #9 pp 74-115, 1985

[116] Widrow B, Lehr MA. 30 years of adaptive neural networks: Perceptron, Madaline, and Backpropagation. Proceedings of the IEEE, vol 78 #9, September 1990, pp 1414-1442.

[117] Jacobs RA. Increased rated of convergence through learning rate adaptation. Neural Network. Vol1 #4, pp 294-308, 1988

[118] Fukushima K. Cognitron: A self organizing multilayered neural network. Biological cybernetics. #20 pp 121-136, 1975

[119] Fukushima K. “Cognitron: A self organizing multilayered neural network for a mechanist of pattern recognition unaffected by shift position ”. Biological cybernetics. #36 pags 193-202, 1980

[120] KOHONEN Tuevo. "Associative memory. A system theoretical approach". Springer-Verlag, 1977

[121]KOHONEN Tuevo. "Learning Vector Quantization". Abstracts of the first annual INNS Meeting, #308, 1988.

[122]KOHONEN Tuevo. "Self-organized formation of topologically correct feature maps". Biological Cybernetics #43 , 1982. Reimpreso en el texto "Neurocomputing" (J.Anderson y E. Rosenfeld ed.), MIT press,1988.

[123]KONONEN Tuevo. "Self-organization and associative memory (3ª ed.)". Springer-Verlag, 1989.

[124] Castillo, E; Gutiérrez, JM; Hadi, AS, Sistemas Expertos y modelos de Redes probabilísticas

[125] Harary, F., editor (1969), *Graph Theory*. Addison-Wesley, Reading, MA.

[126] Golumbic, M. C. (1980), *Algorithmic Graph Theory and Perfect Graphs*. Academic Press, New York.

[127] Liu, C. (1985), *Elements of Discrete Mathematics*. McGraw-Hill, New York.

[128] Ross, K. A. and Wright, C. R. (1988), *Discrete Mathematics*. Prentice Hall, Englewood Cliffs, N.J.

[129] Biggs, N. L. (1989), *Discrete Mathematics, 2nd edition*. Oxford University Press, New York.

[130] Bondy, J. A. and Murty, U. S. R. (1976), *Graph Theory with Applications*. North Holland, New York.

[131] Pearl, J. *Probabilistic Reasoning* in *Intelligent Systems: Networks of Plausible Inference.* Morgan Kaufmann, 1988.

[132] Jensen, F.V. *Bayesian Networks and Decision Graphs.* Springer-Verlag. 200l.

[133] Hernández J., Ramírez J.M., Ferri C. Introducción a la minería de datos, 2004: Pearson, D.L. pp 257-280, 2004. ISBN: 84-205-4091-9

[134] *Morales M., Salmerón A., Rodríguez C. Análisis de indicadores de rendimiento mediante redes bayesianas. ISBN13: 9788482408415, 2007*

[135] A. Joenson, L. Landberg, H. Madsen, A new measure–correlate–predict approach for resource assessment, Proceedings of the EWEC, 1999.

[136] L. Landberg, N.G. Mortenson, A comparison of physical and statistical methods for estimating the
wind resource at a site, Proceedings of the BWEA, 1993

[137] N.G. Mortensen, L. Landberg, I. Troen, E.L. Petersen, Wind Atlas Analysis and Application
Program, vol. 2:Users Guide. Riso-I-666(ENN) (v.2). Riso National Laboratory, Roskilde, Denmark, 133pp.

[138] P.E.J. Vermuelen, A. Marijanyan, A. Abrahamyan, J.H. den Boon, Application of matarix MCP
analysis in mountainous Armenia, Proceedings of the EWEA, 2001.

[139] A.A. Mortimer, A new correlation/prediction method for potential wind farm sites, Mortimer, Proceedings of the BWEA, 1994.

[140] Mardia KV. Families of bivariate distributions. 1st ed. USA: Lubrecht & Cramer Ltd; 1970

[141] Carta JA, Mentado D. A continuous bivariate model for wind power density and wind turbine energy output estimations. Energy Conversion and Management 2007; 48:420-32.

[142] Kiryanov D. The Mathcad 2001i Handbook.1st ed. USA: Delmar Thomson Learning; 2002.

[143] Canavos G. Applied probability statistical methods. 1st ed. New York: Little Brown & Company; 1998.

[144] Akai TJ. Applied numerical methods for engineers. 2nd ed. New York: John Wiley & Sons, Inc. 1994

[145] Peinke J. Wind Energy. Proceeding of the Euromech colloquium. Berlin Heidelberg, 2007

[146] Hernández H Pedro. Natura y Cultura de Las Islas Canarias. Tafor Publicaciones (2003)

[147] Salva Monfort JJ (1982). Energía eólica para las Islas Canarias. Primeras Jornadas sobre Energía Eólica. Marzo, 1992, Tenerife

[148] Font Tullot I (1956). *El tiempo atmosférico en las Islas Canarias.* Servicio Meteorológico Nacional. Publicaciones. Serie A (Memorias). Num. 26

[149] Plan de Acción Nacional de Energías Renovables de España (PANER) 2011 – 2020. Junio 2010.

[150] Estadísticas Energéticas de Canarias. Consejería de Empleo, Industria y Comercio del Gobierno de Canarias, 2004.

[151] Estadísticas Energéticas de Canarias. Consejería de Empleo, Industria y Comercio del Gobierno de Canarias, 2005.

[152] Estadísticas Energéticas de Canarias. Consejería de Empleo, Industria y Comercio del Gobierno de Canarias, 2006.

[153] Informe mensual de Diciembre de 2009. Red Eléctrica de España. Sistema eléctrico canario, 2009.

[154] Orden de 9 de Mayo de 1996, por la que se convoca concurso para la asignación de potencias eléctricas eólicas conectables en cada red eléctrica insular.

[155] http://www.gobiernodecanarias.org/industria/eolica//produccionaerogeneradores.xls

[156] Plan Energético de Canarias 2006-2015 (PECAN 2006-2015). Consejería de Empleo, Industria y Comercio del Gobierno de Canarias, 2005.

[157] Orden de 17 de Mayo de 2007, por la que se convoca concurso público para la asignación de potencia en la modalidad de instalaciones o ampliación de parques eólicos con consumos asociados en los sistemas eléctricos insulares canarios. BOCA nº 102. Mayo 2007: pp 10796-10829

[158] Orden de 27 de abril de 2007, por la que se convoca concurso público para la asignación de potencia en la modalidad de nuevos parques eólicos destinados a verter toda la energía en los sistemas eléctricos insulares canarios. BOCA nº 89. Mayo 2007: 9315-9353

[159] Decreto Legislativo 1/2000, de 8 de Mayo, por el que se aprueba el texto Refundido de las leyes de Ordenación del territorio de Canarias y Espacios Naturales de Canarias. BOCA nº 60. Mayo 2000: pp 5989-6307

[160] http://atlaseolico.idae.es/inc/get_map.php?pdf=spd80_es-ic

[161] Ley 11/1997, de 2 de diciembre, de regulación del Sector Eléctrico Canario. BOCA 158. Diciembre 1997: pp 13829-13837

[162] Barros VR, Estevan EA. On the evaluation of wind power from short wind records. Journal of Climate and Applied Meteorology 1983;22: 1116-23.

[163] Daniels PA, Schroede TA. Siting large wind turbines in Hawaii. Wind Eng. 1988;12: 302–30.

[164] Witten IH, Frank E. Data Mining. Practical Machine Learning Tools and Techniques. 2nd ed. San Francisco: Elsevier;2005.

[165] Enercon GmbH. Enercon Booklets. Enercon wind turbines. Product Overview <www.Enercon.de>.

[166] Gamesa. Gamesa Products. Wind Turbines. Wind turbines Catalogue <www.gamesa.com/en>

[167] Principe JC, Euliano NR, Lefebvre WC. Neural and Adaptive Systems. Fundamentals Through Simulations. first ed. New York: John Wiley & Sons, Inc.; 2000.

[168] Masters T. Practical Neural Network Recipes in C++. first ed. California:Morgan Kaufmann Publishers;1993.

[169] Demuth H. Beale M. Neural network toolbox user's guide. The Math Works, Inc., Natick, MA 01760-2098;2003.

[170] Carta JA, Velazquez S, Matías JM. Use of Bayesian Networks classifiers for long-term mean wind turbine energy output estimation at a potential wind energy conversion site. Energy Conversion and Management, 2011, Vol 52: pp 1137-1149

[171] Putnam PC. Power from the wind. 1st ed. New York:Van Nostrand Reinhold Compay; 1948.

[172] Aspliden CI, Elliott DL, Wendell LL. Resources assessment method, sitting, and performance evaluation. In: Guzzi R, Justus CG. Physical climatology for solar and wind energy, New Jersey: Wold Scientific;1988,p. 321-76.

[173] D.A. Bechrakis DA, Deane JP, McKeogh EJ. Wind resource assessment of an area using short term data correlated to a long term data set. Solar Energy 2004; 76: 725–32.

[174] Cofiño AS, Gutiérrez JM, Jakubiak B, Melonek M. Implementation of data mining techniques for meteorological applications. In: Zwieflholer W. Proceedings of the Tenth ECMWF Works-hop on the Use of High Performance Computing in Meteorology: realizing TeraComputing, U.K: World Scientific Publishing; 2003, p.256-71.

[175] Jensen FV, Nielsen TD. Bayesian Networks and Decision Graphs. Second ed. New York: Springer; 2007.

[176] Castillo E, Gutiérrez JM, Hadi AS. Expert systems and probabilistic network models. 1st ed. New York: Springer-Verlag; 1997.

[177] Pearl J. Probabilistic reasoning in intelligent systems: networks of plausible inference. 1st ed. San Francisco: Morgan Kaufmann; 1988.

[178] Chickering M, Geiger D, Heckerman D. Learning Bayesian networks. In: Ficher D, Lenk H. Learning from data. Artificial Intelligence and Statistics V: Springer-Verlag; 1996, p.121-30.

[179] HeckD, Chickering M, Geiger D. Learning Bayesian networks: the combination of knowledge and statistical data. Machine Learning 19995; 20: 197-244.

[180] Friedman N, Geiger D, Goldszmidt. Bayesian networks classifiers. Machine Learning 1997; 29: 131-63.

[181] Cooper GF, Herskovitz E. A Bayesian method for the induction of probabilistic networks from data. Machine Learning 1992; 9:309-47.

[182] Kennedy S., Rogers P. A Probabilistic Model for Simulating Long-Term Wind-Power Output. Wind Engineering. Vol 27, Nº 3, 2002. pp 167-181

[183] Carta JA, Ramírez P. Use of finite mixture distribution models in the analysis of wind energy in the Canarian Archipelago. Energy Conversion and Management 2007;48:281-91

[184] Carta JA, Ramírez P. Analysis of two-component mixture Weibull statistics for estimation of wind speed distributions. Renewable Energy 2007; 32:518-531

[185] Baker R, Walker SN, Wade JE. Annual and seasonal variations in mean wind speed and wind turbine energy production. Solar Energy 1990; 45:285-9.

[186] Klink K. Trends and interannual variability of wind speed distributions in Minnesota. J. Clim. 2002; 15: 3311-7

[187] Alpaydin E. Introduction to machine learning. Second ed.Massachusetts: The MIT Press; 2010.

[188] Witten IH, Frank E. Data mining. Second ed. New York: Morgan Kaufman Publishers,2005.

[189] Nagelkerke N.A Note on a General Definition of the Coefficient of Determination. Biometrika 1991; 78: 691-2.

[190] Carta JA, Bueno C, Ramírez P. Statistical modelling of directional wind speeds using mixtures of von Mises distributions: Case study. Energy Conversion and Management 2008; 49:897-907.

[191] Dietterich TG. Approximate statistical test for comparing supervised classification learning algorithms. Neural Computation 1998; 10: 1895-1924.

[192] Breslow PB, Sailor DJ. Vulnerability of wind power resources to climate change in the continental United States. Renewable Energy 2002; 27: 585-98.

[193] Manwell JF, McGowan JG, Rogers AL. Wind energy explained. 2nd ed. Great Britain: John Wiley & Sons; 2009.

[194] Nelson V. Wind energy.1st. ed. FL: CRC Press; 2009.

[195] Sherman JM, Gresham MS, Fergason DL. Wind systems life cycle cost analysis. 1st ed. New York: WindBooks; 1983.

[196] Hau E. Wind turbines. 2nd ed. New York: Springer;2005

[197] March F, Dlott EH, Korn DH, Madio FR, McArthur RC, Vachon WA. Wind power for the electric-utility industry. 1st ed. Massachusetts: LexingtonBooks;1982.

[198] Swift-Hook DT. Second wind. The Engineer 1988; 267:30-1

[199] Landberg L, Myllerup L, Rathmann O, Petersen EL, Jørgensen BH, Niels BJ et al. Wind resource estimation—An overview. Wind Energy 2003;6:261-71.

[200] Calero R, Carta JA. Action plan for wind energy development in the Canary Islands. Energy Policy 2004; 32:1185–97.

[201] Mardia KV, Jupp PE. Directional Statistics. 1st ed. West Sussex: John Wiley & Sons Ltd: 2000.

[202] Dawson CW, Abrahart RJ, See LM. HydroTest:. HydroTest: A web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts. Environmental Modelling & Software 2007;22:1034-52.

[203] Reid SJ, Turner R. Correlation of real and model wind speeds in different terrains. Weather and Forecasting 2001; 16: 620-7.

[204] Hurley B, Hughes P, Giebel G. Reliable Power, wind variability and offshore grids in Europe. In: Boyle G, editor. Renewable electricity and the grid, London: Earthscan; 2009, p.181-199.

[205] EWEA. Wind Energy-The facts.1st ed. London: Earthscan; 2009.

[206] Pryor SC, Barthelmie RJ. Climate change impacts on wind energy: A review. Renewable and Sustainable Energy Reviews 2010; 14: 430–7

ANEXO:

Artículos publicados derivados del trabajo de investigación realizado en la tesis

Artículo 1:

Título: “Influence of the level of fit of a density probability function to wind-speed data
on the WECS mean power output estimation”

Revista: Energy Conversion and Management, 2008;49. pp 2647-2655

Artículo 2:

Título: “A review of wind speed probability distributions used in wind energy analysis
Case studies in the Canary Islands”.

Revista: Renewable and Sustainable Energy Reviews, 2009;13. pp 933-955

Articulo 3:

Título: “Use of Bayesian networks classifiers for long-term mean wind turbine energy
output estimation at a potential wind energy conversion site”

Revista: Energy Conversion and Management, 2011; 52. pp 1137–1149

Energy Conversion and Management 49 (2008) 2647–2655

Contents lists available at ScienceDirect

Energy Conversion and Management

journal homepage: www.elsevier.com/locate/enconman

Influence of the level of fit of a density probability function to wind-speed data on the WECS mean power output estimation

José A. Carta [a,*], Penélope Ramírez [b], Sergio Velázquez [b]

[a] Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain
[b] Department of Renewable Energies, Technological Institute of the Canary Islands, Pozo Izquierdo Beach s/n, 35119 Santa Lucia, Gran Canaria, Canary Islands, Spain

ARTICLE INFO

Article history:
Received 7 September 2007
Accepted 13 April 2008
Available online 4 June 2008

Keywords:
Wind speed probability distribution function
Wind turbine energy output
Level of fit
Adjusted determination coefficient

ABSTRACT

Static methods which are based on statistical techniques to estimate the mean power output of a WECS (wind energy conversion system) have been widely employed in the scientific literature related to wind energy. In the static method which we use in this paper, for a given wind regime probability distribution function and a known WECS power curve, the mean power output of a WECS is obtained by resolving the integral, usually using numerical evaluation techniques, of the product of these two functions. In this paper an analysis is made of the influence of the level of fit between an empirical probability density function of a sample of wind speeds and the probability density function of the adjusted theoretical model on the relative error ε made in the estimation of the mean annual power output of a WECS. The mean power output calculated through the use of a quasi-dynamic or chronological method, that is to say using time-series of wind speed data and the power versus wind speed characteristic of the wind turbine, serves as the reference. The suitability of the distributions is judged from the adjusted R^2 statistic (R_a^2). Hourly mean wind speeds recorded at 16 weather stations located in the Canarian Archipelago, an extensive catalogue of wind-speed probability models and two wind turbines of 330 and 800 kW rated power are used in this paper.

Among the general conclusions obtained, the following can be pointed out: (a) that the R_a^2 statistic might be useful as an initial gross indicator of the relative error made in the mean annual power output estimation of a WECS when a probabilistic method is employed; (b) the relative errors tend to decrease, in accordance with a trend line defined by a second-order polynomial, as R_a^2 increases.

© 2008 Elsevier Ltd. All rights reserved.

1. Introduction

There are basically three types of methods for estimating the energy generated by a wind turbine subject to a given wind regime: dynamic methods, which use a time series of wind speeds as data input to a numerical model of operation of a wind turbine [1–3]. With this approach, it is possible to analyse the transitory operation of a WECS (wind energy conversion system) and to carry out research on the effect of different control strategy options or changes. Quasi-dynamic methods or chronological methods [4–9], which use a time series of wind speeds and the characteristic power curve of a WECS [10] to obtain a time series of mean power generated by it. This approach can provide information about the cut-ins and cut-outs experienced by the wind turbine and, therefore, assistance in the management of stand-alone and hybrid systems [4–7]. The methods which we can call static or probabilistic, are based on statistical techniques to determine the mean power generated by a wind turbine in a given period of time, normally in terms of one month, one particular season or one year. Static methods are recommended when the objective is to confirm a site as a potential candidate for the location of a wind farm [7,11,12], and can estimate the mean power output of a WECS in two ways: (a) method of bins, which combines the binned wind speed distribution (if measured site wind speed data is available) with the power curve of a wind turbine [11,13]; (b) method of probability, which combines the probability density function (pdf) of the wind speed with the power curve of a wind turbine [7–9,11–21]. This latter procedure is the one that has been most widely published in the scientific literature, and is the one that we shall use in this paper to analyse the influence of the level of fit between an empirical probability density function of a sample of wind speeds and the probability density function of the adjusted theoretical model on the relative error ε made in the estimation of the mean annual power output of a WECS. The mean power output calculated using a quasi-dynamic or chronological method serves as the reference. The suitability of the distributions is judged from the adjusted R^2 statistic [14,20,22,23].

Hourly mean wind speeds recorded at 16 weather stations located in the Canarian Archipelago [24], an extensive catalogue

* Corresponding author. Tel.: +34 928 45 14 83; fax: +34 928 45 14 84.
E-mail address: jcarta@dim.ulpgc.es (J.A. Carta).

0196-8904/$ - see front matter © 2008 Elsevier Ltd. All rights reserved.
doi:10.1016/j.enconman.2008.04.012

of wind-speed probability models published in the scientific literature [14,23–31] and two Enercon wind turbines of 330 and 800 kW rated power are used in this paper.

As background work related to this paper, we would like to mention specifically the studies carried out by Castro and Ferreira [7], Celik [8], and Chang and Tu [9]. Celik [8] performed a comparison between a static method based on the Weibull distribution and a quasi-dynamic or chronological method. In the analysis the power curve of a wind turbine of 50 kW rated power is used together with series of hourly mean wind speed data from five different locations.[1] Celik [8] reaches the conclusion that the relative errors range between 1.35% and 4.73%. Chang and Tu [9] performed a similar analysis in Taiwan to that carried out by Celik [8], though with half-hourly mean wind speed data, and compared the results that they obtain from both models with measured data at a wind farm consisting of four wind turbines of 660 kW rated power installed in Mailiao. Chang and Tu [9][2] reached the conclusion that the capacity factors calculated from the time-series approach (quasi-dynamic method) have better agreement with the actual capacity factors than the Weibull approach (static method). It should be pointed out that in none of the cited references [7–9] is the level of fit between the Weibull distribution used and the wind speed sample data quantitatively measured.

2. Probabilistic method

In the static method which is based on a pdf, for a given wind regime probability distribution function $f(v, \theta)$[3] at hub height and a known WECS power curve PWT(v), the mean power output of a WECS (assuming 100% availability) is given in the following equation:

$$\overline{P}_p = \int_{v_I}^{v_O} f(v,\theta)\mathrm{PWT}(v)\,\mathrm{d}v \tag{1}$$

where v_I is the cut-in wind speed and v_O is the cut-out wind speed of the wind turbine.

Generally, the integral of Eq. (1) cannot be analytically resolved and, therefore, numerical methods have to be used. In this paper, we have used an integration method[4] of Mathcad® Software programme (version 13) of MathSoft Engineering & Education, Inc. [33].

2.1. Power curves used

As pointed out by Carta and Mentado [18], the power curve of a wind turbine depends on the wind speed and air density. However, in this paper we will assume that the air density[5] is constant or equal to 1.225 kg m^{-3}. This simplification is made so that the results obtained can be compared with those obtained by the cited authors [8,9] and because this assumption is frequently used in the specialised literature.

Some authors use analytic curves with linear, quadratic or cubic forms, or a combination of these, to represent the power curve PWT(v) of a wind turbine [8,9,12,30,34–37]. However, the manufacturers do not usually supply information of the power curves of their wind turbines in a continuous form, but rather in discrete form with N nodes (P_i, v_i). Since the power curves are quite smooth it is possible to carry out an approximation [5,6,21][6] which consists of assuming that the variation between two nodes of the power-wind speed curve is linear. Then, given two points "i" and "$i + 1$" of the power curve, power as a function of speed in this section can be written as Eq. (2)

$$\mathrm{PWT}(v) = \frac{P_{i+1} - P_i}{v_{i+1} - v_i}(v - v_i) + P_i \tag{2}$$

Then, substituting in Eq. (1) we get Eq. (3)

$$\overline{P}_p = \sum_{i=1}^{N-1} \int_{v_i}^{v_{i+1}} f(v,\theta)\left[\frac{P_{i+1} - P_i}{v_{i+1} - v_i}(v - v_i) + P_i\right]\mathrm{d}v \tag{3}$$

In this paper, power curves have been used, for a standard air density of 1.225 kg/m^3, of two commercial wind turbines: Enercon's E-33 wind turbine and Enercon's E-48 wind turbine [39]. These wind turbines have a rated power of 330 and 800 kW, respectively. The hub height for both is 50 m. In Fig. 6 we can see the power curves for both wind turbines.

2.2. Wind-speed probability density functions used

The two parameter Weibull distribution (W-pdf) has been extensively used and has been recommended to describe the frequency distribution of wind speeds for the purpose of evaluating its energy [26]. Based on these arguments, the authors of studies prior to this paper [7–9] have adopted the Weibull distribution to represent the wind regimes of the stations analysed and to calculate the wind energy output of the wind turbines. However, in this paper and with the objective of obtaining a wide range of levels of fit (R_a^2) between the wind speeds of the sample and the pdf with which it is hoped to represent it, an extensive catalogue of pdfs has been used. This catalogue contains practically all the pdfs that have been proposed in the specialised literature to represent wind regimes and to estimate their energy. Moreover, the W-pdf has been unable to represent all the wind regimes encountered in nature such as, for example, those with high percentages of null wind speeds, bimodal distributions, etc. [15,24,25,40].

The pdfs used in this paper are: three parameter generalized gamma distribution [27], two parameter Weibull distribution [26], Two parameter gamma distribution [28], inverse Gaussian (Wald) distribution [29], log-normal distribution [14], three parameter beta distribution [28], singly truncated from below normal distribution [24], Rayleigh distribution [23,41], distributions derived from the maximum entropy principle[7] [25], two components mixture Weibull distribution [15,22,24].

3. Quasi-dynamic method

In the quasi-dynamic or chronological method, the mean power output of a WECS (assuming 100% availability) is given in the following equation:

$$\overline{P}_c = \frac{1}{n}\sum_{i=1}^{n} \mathrm{PWT}(v_i) \tag{4}$$

[1] In Ref. [8], the height above ground level at which the wind speed data were recorded is not specified, nor is the hub height of the wind turbine.

[2] Chang and Tu [9] do not specify in their work the air density considered (the measured power depends on the air density [18]), nor the availability of the turbine, nor the array effects (spacing, wind rose, etc. [13,32]).

[3] θ represents the parameters on which the pdf depends.

[4] It applies an adaptive quadrature method which is useful for functions that change rapidly over an interval.

[5] Most manufacturers only publish the power curves of their wind turbines for an air density of 1.225 kg m^{-3}, corresponding to standard conditions (sea level, 15 °C).

[6] If greater accuracy is desired than the power curve can be approximated by means of cubic spline interpolation [18,38]. Cubic spline interpolation lets you pass a curve through a set of points in such a way that the first and second derivatives of the curve are continuous across each point. This curve is assembled by taking three adjacent points and constructing a cubic polynomial passing through those points. These cubic polynomials are then strung together to form the completed curve.

[7] Constrained by the low-order statistical moments with respect to the origin of the sample. In this paper distributions are used constrained by 2, 3, 4, 5 and 6 moments with respect to the origin [25].

Table 1
Descriptive numerical measurements of the 16 weather stations analyzed

Weather station		Mean	Variance	Minimum	Maximum	Skewness	Kurtosis	Mean of the cubes	Median
Name	Reference	m (m s^{-1})	s^2 (m^2 s^{-2})	v_{min} (m s^{-1})	v_{max} (m s^{-1})	Sk (–)	Kt (–)	m'_3 (m^3 s^{-3})	Me (m s^{-1})
Los Valles	1	8.58	14.43	0	23.53	0.328	2.75	1021	8.25
Taca	2	6.26	9.22	0	20.61	0.339	2.84	427.50	6.10
Antigua	3	7.17	10.83	0	21.35	0.346	3.04	613.16	7.01
P. Jandía 1	4	7.95	12.56	0	22.20	−0.126	2.664	797.20	8.13
Amagro	5	8.72	19.22	0	26.87	0.111	2.44	1176	8.78
R Prieto	6	6.79	11.20	0	20.97	0.11	2.51	545.09	6.87
P. Galdar	7	6.50	8.47	0	19.28	0.081	2.82	441.38	6.45
F. Sardina	8	9.98	17.22	0	27.04	−0.245	3.06	1493	10.48
Gando	9	7.14	12.194	0	20.29	−0.216	2.20	615.73	7.58
M. Diablo	10	9.06	21.83	0	20.32	−0.016	2.03	1334	9.15
P. Vargas	11	7.20	13.67	0	17.26	−0.01	2.05	668.53	7.32
P. Izquierdo	12	9.00	20.76	0.1	20.83	−0.087	2.13	1280	9.25
Granadilla	13	7.91	18.80	0	22.088	0.232	2.102	960.28	7.78
El Rayo	14	5.50	8.88	0	16.74	0.181	2.34	318.02	5.40
Valverde	15	10.99	34.84	0	27.40	0.033	2.19	2484	11.16
S. Sebastián	16	7.309	15.02	0	23.56	0.175	2.605	729.98	7.53

where n is the number of wind speed data recorded in the period of analysis considered and PWT(v_i) is the power of the wind turbine for the wind speed v_i and is given by Eq. (2).

4. Wind speeds used

The wind speeds used in this paper were obtained during the period 1988–2004 from a series of weather stations set up in the Canarian Archipelago (Spain) in order to study the wind energy capacity of the Islands [42]. A total of 16 weather stations were chosen for the analysis conducted in this paper [24]. The criteria for selection were that the weather stations should have data for full year periods and that the various histogram shapes of wind speeds recorded throughout the islands be represented.

As indicated in Ref. [24], the anemometers were installed at a height of 10 m above ground level (agl), with the exception of the weather stations named Los Valles and P. Galdar whose anemometers were installed at 18 and 15 m agl, respectively.

The recorded speeds were extrapolated to a height of 50 m agl (coinciding with the hub height of the wind turbines used in this study), using a power law [13,32]. The power law exponent was determined using the equation proposed by Spera and Richards [43], which takes into account the surface roughness length and the wind speed at the reference height or measurement height.[8] The surface roughness length of each weather station was selected on the basis of visual inspection of the terrain and reference to tables [30], and are in the range of 0.001–0.055 m.

Table 1 shows, for each of the 16 selected weather stations, the name of the station, the assigned reference number and, for the height of 50 m agl, the mean, variance, minimum and maximum recorded wind speed, coefficient of skewness, coefficient of kurtosis, the mean of the cube of the wind speed, median and mode.

In Figs. 1 and 2 we can see the corresponding wind speed frequency histograms for the 16 stations analysed. These histograms have been made from estimated wind speeds (through the use of the power law) at 50 m above ground level.

5. Methodology of the analysis

Once the hourly wind speeds have been estimated, at hub height (50 m) of the wind turbines, for the 16 stations analysed, the following steps were employed with respect to the methodology:

1. Estimation of the parameters of the different probability density functions selected to represent the wind regimes of the 16 stations under consideration. The estimation method used was that of maximum likelihood (ML) [22,26,44,45], with the exception of the distributions generated using the maximum entropy principle [25].[9]
2. Estimation of the adjusted R^2 statistic (R^2_a)[10] [47], with the aim of judging the level of fit between the empirical probability density functions (EPDF) of the 16 stations analysed and the probability density function of the adjusted theoretical model (pdf).
   Of the methods that can be used to estimate the empirical density function [48] the histogram has been chosen. This is the oldest and most widely used method as an estimator of probability densities. The fixed partition histogram with origin at 0 m/s and with bins of equal width, is constructed using intervals of the type $I_k = [(k-1)w, kw)$,[11] with k being whole.Mathematically, the histogram is defined in the following equation:

$$f_H(v) = \frac{\sum_{i=1}^{n} A_{I_k}(V_i)}{nw}, \quad \text{if } v \in I_k \tag{5}$$

   where n is the number of hourly mean wind speed data of the sample, and $A_{I_k}(u)$ is the indicator function of the interval I_k, which is 1 provided that $u \in I_k$ and is otherwise 0. The result is a step function, constant at each interval of the partition, with area equal to 1, which is 0 for those intervals where no sample data falls.[12]
   The R^2 will be given by Eq. (6), where p_i are the relative frequencies of the sample given by Eq. (5), $\hat{p}_i$ are the probabilities obtained with the probability model at each interval I_k, $\bar{p}$ is the mean of the p_i values and N is the total number of intervals [47].

[8] The power law proposed by Spera and Richard [43] has been chosen because, apart from its simplicity, it acceptably represents the vertical wind profiles at various stations installed in the Canary Islands for which wind speed measurements are available for two heights above ground level (10 and 20 m), and also because the aim of this paper can thus be covered without the need to resort to more complicated models.

[9] Maximum likelihood estimators of statistical moments with respect to the origin of maximum entropy distributions are given by the statistical moments with respect to the origin of the samples [46].

[10] The value of R^2_a varies between 0 and 1. The higher R^2_a, the greater the fit.

[11] The intervals have been chosen closed on the left and open on the right for definiteness.

[12] Some authors join together, with line segments, the midpoints of the upper bases of each rectangular bar of the histogram to obtain a frequency polygon.

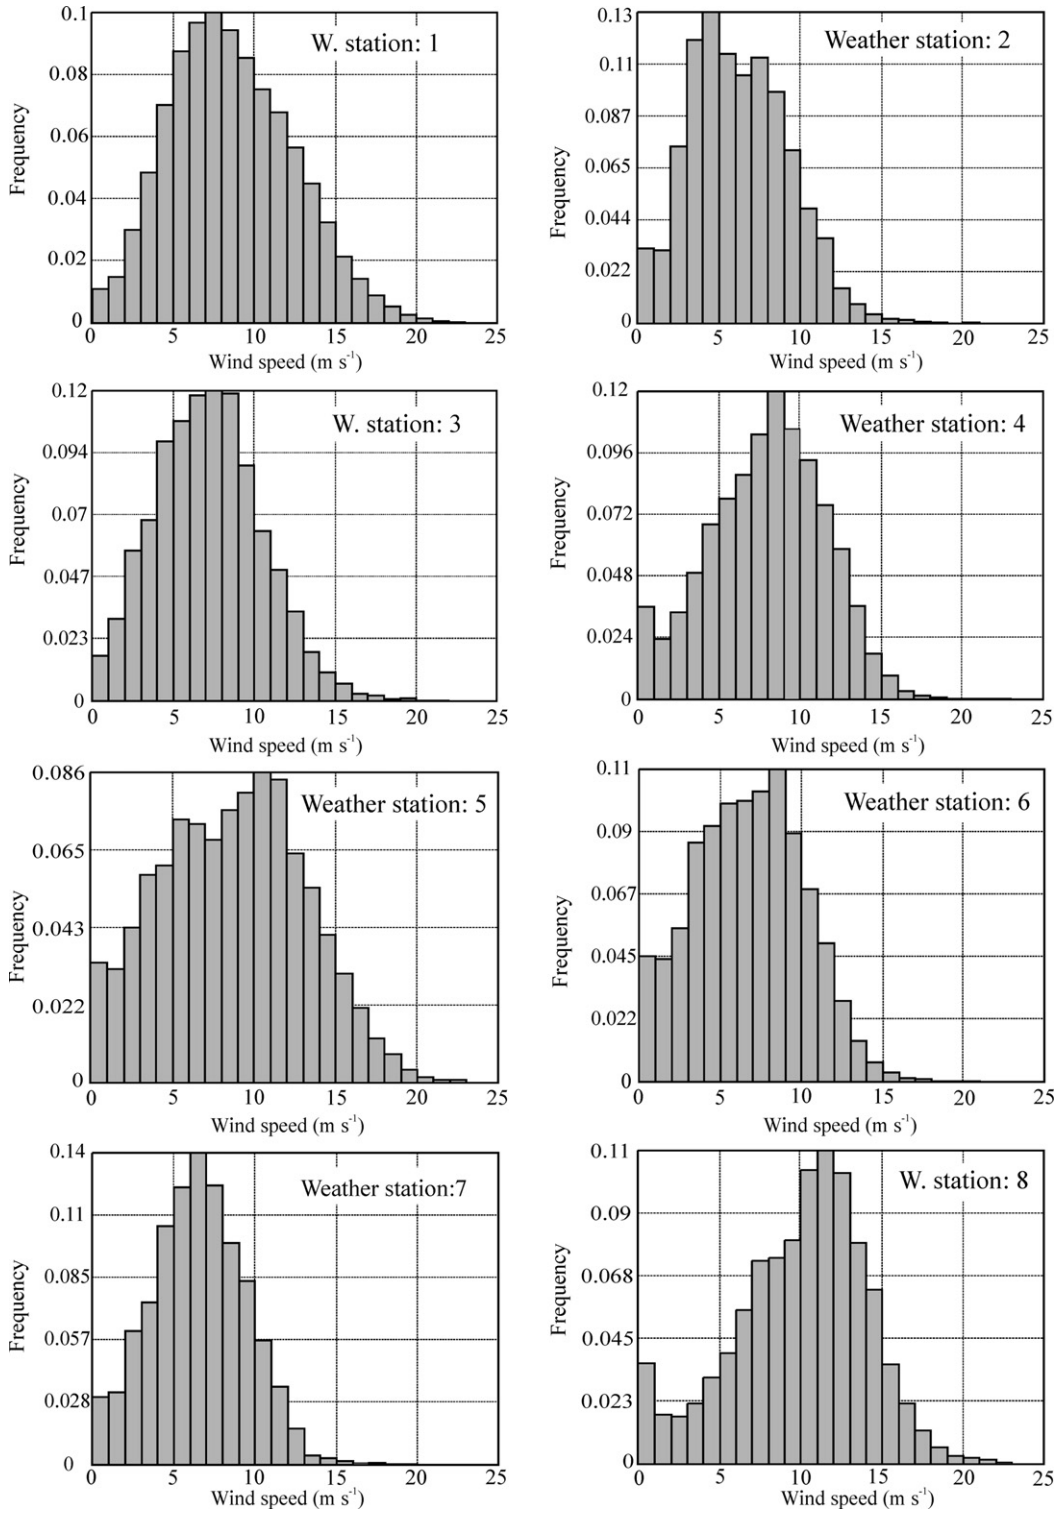

Fig. 1. Histogram of the sample of wind speeds in stations 1–8.

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(p_i - \hat{p}_i)^2}{\sum_{i=1}^{N}(p_i - \bar{p})^2} \tag{6}$$

R_a^2 is defined by Eq. (7)

$$R_a^2 = 1 - (1 - R^2)\left(\frac{N-1}{N-pa}\right) \tag{7}$$

where pa is the total number of parameters in a fitted model. The idea is that the R_a^2 statistic can be used to compare models fitted not only to a specific set of data but also to two or more entirely different sets of data.

3. Estimation of the mean powers $\overline{P}_p$ generated by the selected wind turbines at each of the stations under consideration, using the different pdfs and Eq. (3).

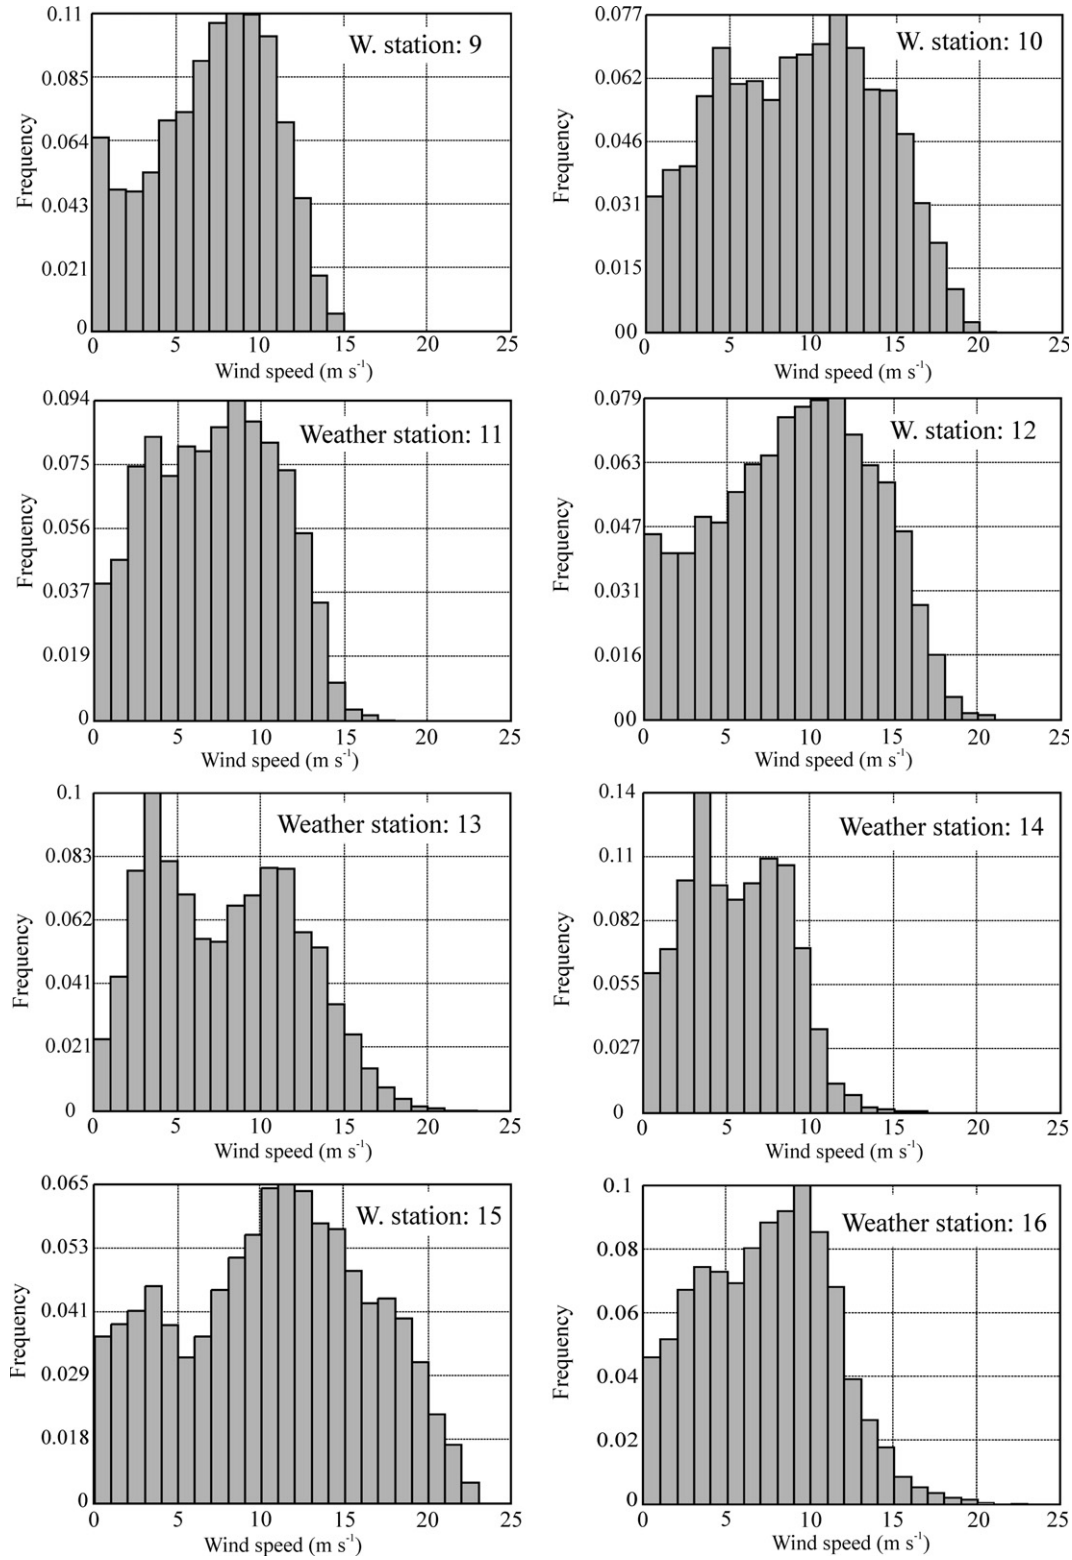

Fig. 2. Histogram of the sample of wind speeds in stations 9–16.

4. Estimation of the mean powers $\overline{P}_c$ generated by the selected wind turbines at each of the stations under consideration, using Eq. (4).
5. Estimation of the relative errors ε existing between the mean powers obtained through step (3) and through step (4). In Eq. (8) n_{ws} is the number of stations used, n_{pdf} is the number of pdfs used and n_{wt} is the number of selected wind turbines

$$\varepsilon_i = \left|\frac{P_{c,i} - P_{p,i}}{P_{c,i}}\right|, \quad i = 1 \ldots n_{ws} n_{pdf} n_{wt} \tag{8}$$

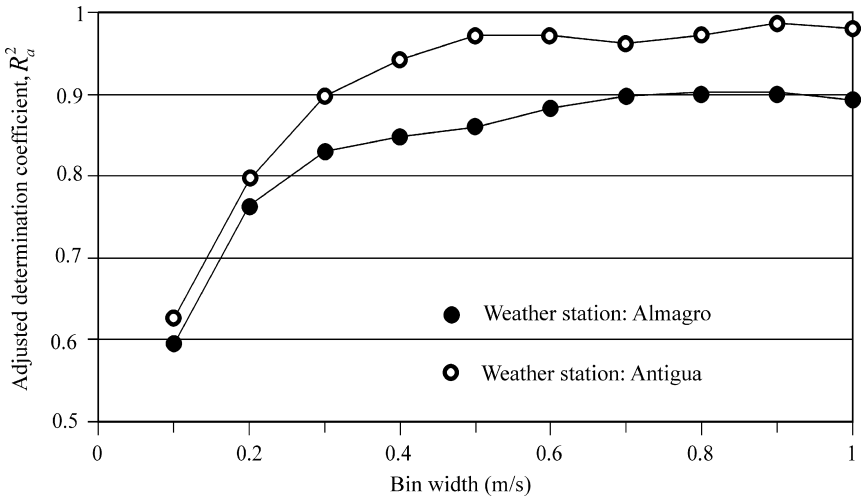

Fig. 3. Relation between R_a^2 and the bin width w of the histogram of wind speeds for the case of the stations named Almagro and Antigua and the Weibull probability density function.

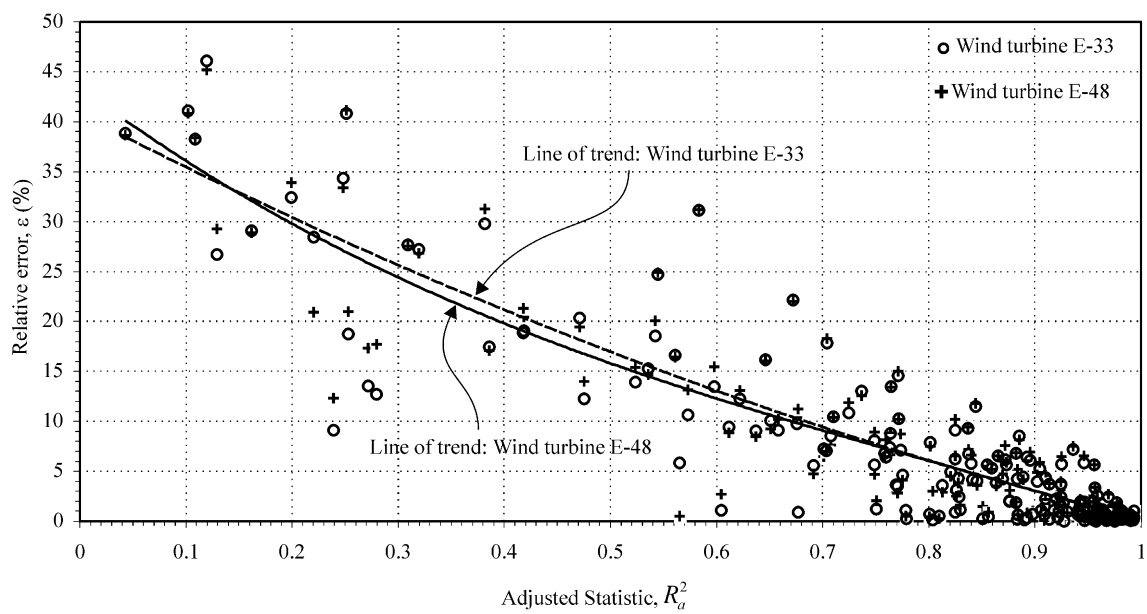

Fig. 4. Relation between the R_a^2 statistic and the relative errors ε.

6. Analysis of results

One of the problems that arise with the histogram method for estimating the empirical density function is that of choosing the width of the intervals w. Usually, the lower the width of the partition intervals the higher the jump discontinuities. It is clear that, when taking a very small value of w one only manages to obtain the same information that the original data showed graphically, while too large a choice for w leads to the loss of the structure present in the sample. In Fig. 3 we can see, by way of example,[13] the rising tendency shown by the R_a^2 statistic as the width w of the intervals of the histogram increases. At the present time there are highly sophisticated methods for choosing w [48], however, since the use of intervals of 1 m/s is commonly used in scientific literature related to wind energy, this will be the interval employed in this paper, as can be seen in the histograms seen in Figs. 1 and 2.

Fig. 4 shows, for the two analysed wind turbines (E-33 and E-48), the relative errors ε (between the mean powers obtained with the probabilistic method and the chronological method) as a function of the coefficients R_a^2. All the stations and pdfs under consideration in this paper have been used to draw up this figure. The variability of the sample of R_a^2 is in the range 0.042948–0.993406. It should be noted that this range would be different if, instead of estimating R_a^2 based on the fit between the empirical probability density function and the probability density function of the adjusted theoretical model, it were to be estimated based on the fit between the empirical distribution function and the distribution function of the adjusted theoretical model [22]. In Fig. 5 we can see, by way of example, how the R_a^2 statistic estimated based on the distribution function is greater than that estimated based on the probability density function.[14]

[13] The stations of Antigua and Almagro and the two parameter Weibull distribution have been used for this figure.

[14] The stations named Antigua, Almagro and Valverde and all the probability models used in this paper have been employed for this figure.

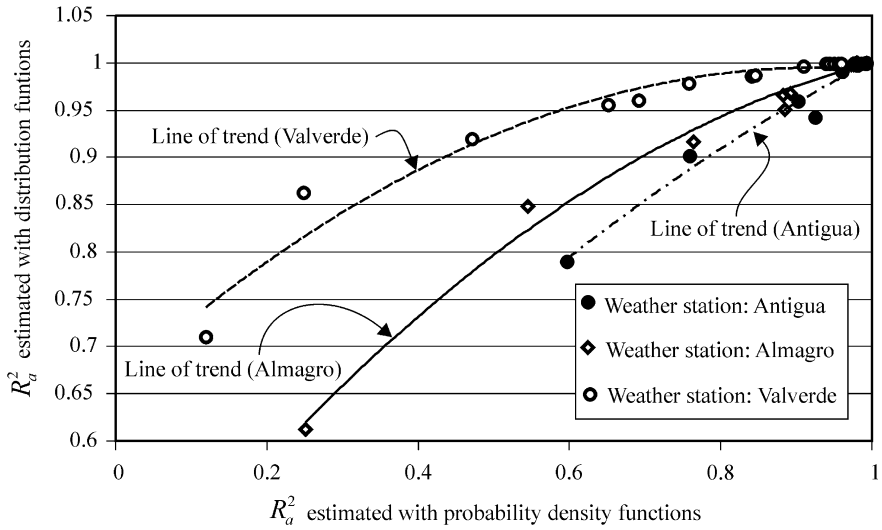

Fig. 5. Relation between the values of R_a^2 estimated with probability density functions and with distribution functions, for the case of the stations named Antigua, Almagro and Valverde.

Likewise, in Fig. 5 we can see the trend line of the two sets of data. In both cases, a second-order polynomial describes the relation between R_a^2 and ε. The equation of the model of fit for the case of wind turbine E-33, is given in the following equation:

$$\varepsilon\ (\%) = 40.7893 - 54.7567R_a^2 + 14.2431(R_a^2)^2 \quad (9)$$

The equation of the model of fit for the case of wind turbine E-48, is given in the following equation:

$$\varepsilon\ (\%) = 40.5982 - 56.4921R_a^2 + 16.1546(R_a^2)^2 \quad (10)$$

Given that the p-value in the ANOVA table is lower than 0.01, there is a statistically significant relation between ε and R_a^2 at the 99% confidence level in both cases. The R-squared statistic indicates that Eq. (9) explains 83.06% of the variability in ε. The adjusted R-squared statistic for two degrees of freedom, which is more convenient for comparing models with different numbers of independent variables, is 82.91%.

The R-squared statistic indicates that Eq. (10) explains 81.43% of the variability in ε. The adjusted R-squared statistic for two degrees of freedom is 81.26%.

In Fig. 4 we can see the tendency to decrease shown by the relative error ε as the coefficient R_a^2 increases. Likewise, it can be seen in this figure that the scattering of the results decreases as R_a^2 increases. It should be noted that the scattering of results is due to the fact that the R_a^2 statistic used to compare models fitted to different samples of data is not high. R_a^2, for this purpose, might be useful as an initial gross indicator [46].

A combination of various factors also has an effect on the deviation from the points in terms of the tendency for ε to decrease as R_a^2 increases: (a) the relative position of the probability density functions with respect to the speed axis in its pairing with the power curves of the wind turbines; (b) the degree of fit between the empirical probability density function of the sample of wind speeds and the probability density function of the adjusted

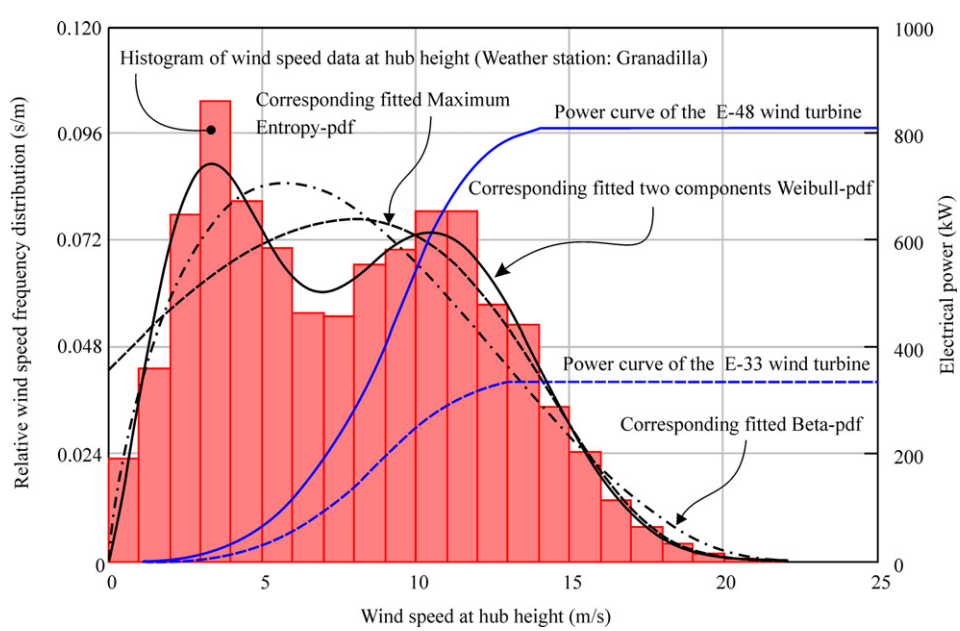

Fig. 6. Example of the influence of pairing between the wind speed probability density functions and the power curves of the wind turbines.

theoretical model in the speed range between the cut-in and cut-out velocity of the wind turbine; (c) the shape of the histogram (asymmetry and kurtosis).

In order to corroborate the effect of these factors, and by way of example, we can see in Fig. 6 the reason why two points A ($R_a^2 = 0.809722$, $\varepsilon = 0.232$) and B ($R_a^2 = 0.820363, \varepsilon = 4.476$), coming from the same sample (Granadilla), do not follow the general rule that the higher that the value of R_a^2 is the lower the value of ε has to be. The fact that point B, despite having a higher R_a^2 than that of point A, has a higher relative error ε than point A, is due to the fact that globally the Beta distribution law (representative of point B) fits better the empirical data than the maximum entropy distribution constrained by the 5 low-order statistical moments with respect to the origin of the sample (representative of point A). However, the maximum entropy distribution fits the empirical data better than the Beta distribution in the speed range between the cut-in velocity and the cut-out velocity of the wind turbine. On the other hand, point C ($R_a^2 = 0.967582, \varepsilon = 0.072$) does follow the general rule. This is due to the fact that the two components mixture Weibull distribution which point C presents fits the empirical data better, both overall and in the speed range corresponding to the power curve of the wind turbine, than the two representative distributions of points A and B. The higher the value of R_a^2 is of a given sample the better will be the fit of the distribution which represents it to all the sections of the empirical histogram. Thus, for high values of R_a^2 the general rule that relates R_a^2 with ε is more reliable. Values of R_a^2 greater than or equal to 0.7, 0.8 and 0.9 have given, for all the stations analysed, relative errors lower than 18%, 11.5% and 7.2%, respectively. Values of R_a^2 greater than or equal to 0.99 have given, for all the stations analysed, relative errors lower than 1%, and in 93.33% of the cases lower than 0.5%.

7. Conclusions

An analysis has been performed in this paper of the influence of the level of fit between empirical probability density functions of samples of wind speeds and probability density functions of adjusted theoretical models on the relative error ε made in the estimation of the mean annual power output of a WECS. The conclusions reached are: (a) that the R_a^2 statistic might be useful as an initial gross indicator of the relative error ε made in the estimation of the mean annual power output of a WECS when a probabilistic method is employed; (b) independently of the nominal power of the wind turbine used, the relative errors tend to decrease, following a trend line defined by a second-order polynomial, as R_a^2 increases; (c) the scattering of the results decreases as R_a^2 increases.

The conclusion is also drawn that the deviation from the points with respect to the tendency to decrease which ε presents as R_a^2 increases is the consequence of: (1) the fact the R_a^2 statistic used to compare models fitted to different data samples is not high and (2) the combination of several factors: (a) the relative position of the probability density functions with respect to the speed axis in its pairing with the power curves of the wind turbines; (b) the degree of fit between the empirical probability density function of the sample of wind speeds and the probability density function of the adjusted theoretical model in the speed range between the cut-in and cut-out velocity of the wind turbine; (c) the shape of the histogram (asymmetry and kurtosis).

The results obtained for the 16 stations and 14 pdfs used have indicated that: (a) values of R_a^2 greater or equal to 0.7, 0.8 and 0.9 generate relative errors lower than 18%, 11.5% and 7.2%, respectively; (b) values of R_a^2 greater or equal to 0.99 generate relative errors lower than 1%, and in 93.33% of the cases lower than 0.5%.

References

[1] Hau E. Wind turbines. Fundamentals, technologies, application, economics. Germany: Springer; 2000.
[2] Heier S. Grid Integration of wind energy conversion systems. 1st ed. Chichester: John Wiley & Sons Ltd; 1996.
[3] Lubosny Z. Wind turbine operation in electric power systems. 1st ed. Berlin: Springer; 2003.
[4] Carta JA, González J. Self-sufficient energy supply for isolated communities: wind-diesel systems in the Canary Islands. Energ J 2001;22:115–45.
[5] Bueno C, Carta JA. Technical–economic analysis of wind-powered pumped hydrostorage systems. Part I: model development. Solar Energ 2005;78:382–95.
[6] Bueno C, Carta JA. Wind powered pumped hydro storage systems, a means of increasing the penetration of renewable energy in the Canary Islands. Renew Sust Energ Rev 2006;10:312–40.
[7] Castro RM, Ferreira AFM. A comparison between chronological and probabilistic methods to estimate wind power capacity credit. IEEE Trans Power Syst 2001;16:904–9.
[8] Celik AN. Energy output estimation for small-scale wind power generators using Weibull-representative wind data. J Wind Eng Ind Aerodyn 2003;91:693–707.
[9] Chang T-J, Tu Y-L. Evaluation of monthly capacity factor of WECS using chronological and probabilistic wind speed data: A case study of Taiwan. Renew Energ 2007;32:1999–2010.
[10] IEC 61400-12. Wind turbine generator systems – Part 12: Wind turbine power performance testing. 1st ed. International Electrotechnical Commission; 1998–2002.
[11] Burton T, Sharpe D, Jenkins N, Bossanyi E. Wind energy handbook. 1st ed. England: John Wiley and Sons, Ltd; 2001.
[12] Koeppl GW. Putnam's power from the wind. 2nd ed. New York: Van Nostrand Reinhold; 1982.
[13] Manwell JF, McGowan JG, Rogers AL. Wind energy explained. 1st ed. England: John Wiley and Sons, Ltd; 2002.
[14] García A, Torres JL, Prieto E, De Francisco A. Fitting wind speed distributions: a case study. Solar Energ 1998;62:139–44.
[15] Jaramillo OA, Borja MA. Wind speed analysis in La Ventosa, Mexico: a bimodal probability distribution case. Renew Energ 2004;29:1613–30.
[16] Jamil M. Wind power statistics and evaluation of wind energy density. Wind Eng 1994;18:227–40.
[17] Hussain M, Alam S, Reza KA, Sarkar M. A study of the wind speed and wind energy availability in Bangladesh. Energ Convers Manage 1986;26:321–7.
[18] Carta JA, Mentado D. A continuous bivariate model for wind power density and wind turbine energy output estimations. Energ Convers Manage 2007;48:420–32.
[19] Mejía JM, Chejne F, Smith R, Rodríguez LF, Fernández O, Dyner I. Simulation of wind energy output at Guajira, Colombia. Renew Energ 2006;31:383–99.
[20] Akpinar EK, Akpinar S. An assessment on seasonal analysis of wind energy characteristics and wind turbine characteristics. Energ Convers Manage 2005;46:1848–67.
[21] Troen I, Petersen EL. European wind atlas. 1st ed. Denmark: Risø National Laboratory; 1989.
[22] Carta JA, Ramírez P. Analysis of two-component mixture Weibull statistics for estimation of wind speed distributions. Renew Energ 2007;32:518–31.
[23] Celik AN. A statistical analysis of wind power density based on the Weibull and Rayleigh models at the southern region of Turkey. Renew Energ 2003;29:593–604.
[24] Carta JA, Ramírez P. Use of finite mixture distribution models in the analysis of wind energy in the Canarian Archipelago. Energ Convers Manage 2007;48:281–91.
[25] Ramírez P, Carta JA. The use of wind probability distributions derived from the maximum entropy principle in the analysis of wind energy. A case study. Energ Convers Manage 2006;47:2564–77.
[26] Ramírez P, Carta JA. Influence of the data sampling interval in the estimation of the parameters of the Weibull wind speed probability density distribution. A case study. Energ Convers Manage 2005;46:2419–38.
[27] Auwera V, Meyer LF, Malet LM. The use of the Weibull three parameter model for estimating mean wind power densities. J Appl Meteor 1980;19: 819–25.
[28] Lavagnini A, Stellato G, Tosato GC. Climatological analysis of Italian data for wind energy applications. In: Palz W, Schnell W, editors. Wind energy. Holland: Reidel Publishing Company; 1982. p. 97–103.
[29] Bardsley WE. Note on the use of the inverse Gaussian distribution for wind energy applications. J Appl Meteor 1980;19:1126–30.
[30] Haslett J, Kelledy E. A note on the use of the models in the estimation of wind power availability. Wind Eng 1981;5:6–11.
[31] Chade JC, Sharma C. Wind speed distributions: a new catalogue of defined models. Wind Eng 2001;25:319–37.
[32] Spera DA. Wind turbine technology. 3rd ed. New York: ASME; 1995.
[33] Larsen RW. Introduction to MathCAD 13. 2nd ed. NJ: Prentice-Hall; 2006.
[34] Lysen EH. Introduction to wind energy. 2nd ed. The Netherlands: Consultancy Services Wind Energy Developing Countries; 1983.
[35] Jones CN. Notes on the effect of site wind-speed frequency distribution and machine performance characteristics on the annual energy output of a WECS. Wind Eng 1986;10:31–46.
[36] Jones CN. The prediction of wind turbine energy output; a brief survey. Wind Eng 1988;12:76–87.

[37] Sasi KK, Basu S. On the prediction of capacity factor and selection of size of wind electric generators – a study based on Indian sites. Wind Eng 1997;21:73–88.
[38] Akai TJ. Applied numerical methods for engineers. 2nd ed. New York: John Wiley & Sons, Inc; 1994.
[39] Enercon GmbH. Enercon wind turbines. Product overview. Germany: Enercon GmbH, www.Enercon.de.
[40] Takle ES, Brown JM. Note on the use of Weibull statistics to characterise wind-speed data. J Appl Meteor 1978;17:556–9.
[41] Hennessey JP. A comparison of the Weibull and Rayleigh distributions for estimating wind power potential. Wind Eng 1978;2:156–64.
[42] Calero R, Carta JA. Action plan for wind energy development in the Canary Islands. Energ Policy 2004;32:1185–97.
[43] Spera DA, Richards TR. Modified power law equations for vertical wind profiles. In: Proceedings of conference and workshop on wind energy characteristics and wind energy siting. Portland (OR); June 19–21, 1979. p. 57–8.
[44] Bury K. Statistical distributions in engineering. 1st ed. UK: Cambridge University Press; 1999.
[45] Johnson NL, Kotz S, Balakrishnan N. Continuous univariate distributions, 2nd ed., vol. 1. New York: John Wiley & Sons; 1995.
[46] Kapur JN. Maximum entropy models in science and engineering. 2nd ed. India: Wiley Eastern Limited; 1993.
[47] Draper NR, Smith H. Applied regression analysis. 1st ed. New York: John Wiley & Sons, Inc; 1998.
[48] Silverman BW. Density estimation for statistics and data analysis. 5th ed. London: Chapman & Hall; 1994.

Renewable and Sustainable Energy Reviews 13 (2009) 933–955

Contents lists available at ScienceDirect

Renewable and Sustainable Energy Reviews

journal homepage: www.elsevier.com/locate/rser

A review of wind speed probability distributions used in wind energy analysis Case studies in the Canary Islands

J.A. Carta [a,*], P. Ramírez [b], S. Velázquez [c]

[a] Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Gran Canaria, Canary Islands, Spain
[b] Department of Renewable Energies, Technological Institute of the Canary Islands, Pozo Izquierdo Beach s/n, 35119 Santa Lucía, Gran Canaria, Canary Islands, Spain
[c] Department of Electronics and Automatics Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Gran Canaria, Canary Islands, Spain

ARTICLE INFO

Article history:
Received 2 April 2008
Accepted 12 May 2008

Keywords:
Probability density distribution
Wind power density
Coefficient of determination
Moments method
Maximum likelihood method
Least squares method

ABSTRACT

The probability density function (PDF) of wind speed is important in numerous wind energy applications. A large number of studies have been published in scientific literature related to renewable energies that propose the use of a variety of PDFs to describe wind speed frequency distributions. In this paper a review of these PDFs is carried out. The flexibility and usefulness of the PDFs in the description of different wind regimes (high frequencies of null winds, unimodal, bimodal, bitangential regimes, etc.) is analysed for a wide collection of models. Likewise, the methods that have been used to estimate the parameters on which these models depend are reviewed and the degree of complexity of the estimation is analysed in function of the model selected: these are the method of moments (MM), the maximum likelihood method (MLM) and the least squares method (LSM). In addition, a review is conducted of the statistical tests employed to see whether a sample of wind data comes from a population with a particular probability distribution. With the purpose of cataloguing the various PDFs, a comparison is made between them and the two parameter Weibull distribution (W.pdf), which has been the most widely used and accepted distribution in the specialised literature on wind energy and other renewable energy sources. This comparison is based on: (a) an analysis of the degree of fit of the continuous cumulative distribution functions (CDFs) for wind speed to the cumulative relative frequency histograms of hourly mean wind speeds recorded at weather stations located in the Canarian Archipelago; (b) an analysis of the degree of fit of the CDFs for wind power density to the cumulative relative frequency histograms of the cube of hourly mean wind speeds recorded at the aforementioned weather stations.

The suitability of the distributions is judged from the coefficient of determination R^2.

Amongst the various conclusions obtained, it can be stated that the W.pdf presents a series of advantages with respect to the other PDFs analysed. However, the W.pdf cannot represent all the wind regimes encountered in nature such as, for example, those with high percentages of null wind speeds, bimodal distributions, etc. Therefore, its generalised use is not justified and it will be necessary to select the appropriate PDF for each wind regime in order to minimise errors in the estimation of the energy produced by a WECS (wind energy conversion system). In this sense, the extensive collection of PDFs proposed in this paper comprises a valuable catalogue.

© 2008 Elsevier Ltd. All rights reserved.

Contents

1. Introduction . . . 934
2. Overview of proposed wind speed probability density distributions . . . 936
3. Methods used for the estimation of parameters and statistical tests . . . 938
   3.1. Methods used in the estimation of parameters . . . 938
   3.2. Considered statistical decisions . . . 938
   3.3. Notes on the methods and tests used . . . 938

* Corresponding author. Tel.: +34 928 45 14 83; fax: +34 928 45 14 84.
E-mail address: Jcarta@dim.ulpgc.es (J.A. Carta).

1364-0321/$ – see front matter © 2008 Elsevier Ltd. All rights reserved.
doi:10.1016/j.rser.2008.05.005

4. Review of mathematical/numerical modelling of PDFs . . . 939
4.1. Three parameter generalised gamma distribution . . . 939
4.1.1. Moment estimates of the parameters . . . 939
4.1.2. Maximum likelihood estimates of the parameters . . . 939
4.2. Two parameter gamma distribution . . . 939
4.2.1. Moment estimates of the parameters . . . 940
4.2.2. Maximum likelihood of the parameters . . . 940
4.3. Two parameter Weibull distribution . . . 940
4.3.1. Moment estimates of the parameters . . . 940
4.3.2. Maximum likelihood estimates of the parameters . . . 940
4.3.3. Least square estimates of the parameters . . . 940
4.4. One parameter Rayleigh distribution . . . 940
4.4.1. Moment estimator of the parameter . . . 941
4.4.2. Maximum likelihood estimator of the parameter . . . 941
4.4.3. Least square estimator of the parameter . . . 941
4.5. Two parameter square-root normal distribution (SRN.pdf) . . . 941
4.5.1. Moment estimates of the parameters . . . 941
4.5.2. Maximum likelihood estimates of the parameters . . . 941
4.6. Two parameter normal truncated distribution (NT.pdf) . . . 941
4.6.1. Moment estimates of the parameters . . . 941
4.6.2. Maximum likelihood estimates of the parameters . . . 941
4.7. Two parameter lognormal distribution (LN.pdf) . . . 942
4.7.1. Moment estimates of the parameters . . . 942
4.7.2. Maximum likelihood estimates of the parameters . . . 942
4.8. Two parameter inverse Gaussian distribution . . . 942
4.8.1. Moment estimates of the parameters . . . 942
4.8.2. Maximum likelihood estimates of the parameters . . . 942
4.9. Three parameter beta distribution (B.pdf) . . . 942
4.9.1. Moment estimates of the parameters . . . 942
4.9.2. Maximum likelihood estimates of the parameters . . . 942
4.10. Two components mixture Weibull distribution (MWW.pdf) . . . 943
4.10.1. Moment estimates of the parameters . . . 943
4.10.2. Maximum likelihood estimates of the parameters . . . 943
4.11. Singly truncated normal Weibull mixture distribution (MTNW.pdf) . . . 943
4.11.1. Moment estimates of the parameters . . . 943
4.11.2. Maximum likelihood estimates of the parameters . . . 943
4.12. Maximum entropy probability density function (ME_M.pdf) . . . 946
4.12.1. Moment estimates of the parameters . . . 946
5. Wind speeds used . . . 947
6. Analysis of the results obtained . . . 948
7. Conclusions . . . 951
References . . . 952

1. Introduction

The probability density function (PDF) of wind speed is important in numerous wind energy applications [1,2]. From the 1940s to the present day, a large number of studies have been published in the scientific literature related to renewable energies that propose the use of a variety of PDFs to describe wind speed frequency distributions [1–197,199–205]. These proposals range from standard parametric distributions [1–11,21–61,63–185,187–189,197,199] to distributions generated by applying the principle of maximum entropy [154,204,205]. Both bivariable [12–20,147,202] and univariable distributions [1–11,21–61,63–146,148–197,199–205] have been proposed. The suggestion has also been made to use unimodal [1–153,156–197,199], bimodal and bitangential[1] [20,154,155,200–205] and hybrid distributions [186,190–196].

A review is carried out in this paper of a wide collection of PDFs which have been proposed for wind energy analysis, as well as of other new ones which are considered here. Likewise, the methods are reviewed which have been proposed to estimate the parameters on which these distribution laws depend, as well as the statistical tests used to see whether a sample of wind data comes from a population with a particular probability distribution.

With the aim of cataloguing the goodness of fit of the different models which are included in this paper, a comparison is made between them and the two parameter Weibull distribution, the most widely used and accepted distribution in the specialised literature on wind energy and other renewable energy sources. This comparison is based on: (a) an analysis of the degree of fit of the continuous cumulative distribution functions (CDFs) for wind speed to the cumulative relative frequency histograms of hourly mean wind speeds recorded at weather stations located in the Canarian Archipelago (Spain) [206]; (b) an analysis of the degree of fit of the CDFs for wind speed density[2] to the cumulative relative

[1] This occurs if there are two distinct points, v_1, v_2, at which there is a common tangent to the density curve. Thus, bitangentiality is implied by, but does not imply bimodality. Informally, bimodality implies an extra hump, but bitangentiality merely an extra bump [201].

[2] The PDFs for wind power density allow notice to be given of the importance of the winds of intensity between two given values, from the point of view of power production. The mode of the PDF for wind power density shows the most energetic ranges of wind speed at the design site. Thus, this mode can be used as a wind turbine design parameter, as annual energy production is usually a maximum if a wind turbine is designed for maximum aerodynamic efficiency at this mode [174,182,185,202].

Nomenclature

a,b	interval limits where a PDF is defined
$B(\cdot,\cdot)$	beta function
B.pdf	three parameter beta probability density function dependent on wind speed v and a set of parameters ϕ
CDF	cumulative distribution function
$f(v,\boldsymbol{\phi})$, $f(v)$	non-hybrid probability density function
fr	a vector which contains the relative frequencies corresponding to the N intervals in which the n wind speed data of a sample are classified. Its components are expressed: fr_i (i = 1, ..., n)
$F(v,\boldsymbol{\phi}), F(v)$	cumulative distribution function dependent on wind speed v and a set of parameters ϕ.
G.pdf	two parameter gamma probability density function
GG.pdf	three parameter generalised gamma probability density function
$h(v,\boldsymbol{\phi},\theta_0), h(v)$	hybrid probability density function dependent on wind speed v and a set of parameters ϕ and θ_0. Eq. (2)
$H(v,\boldsymbol{\phi},\theta_0), H(v)$	hybrid cumulative distribution function dependent on wind speed v and a set of parameters ϕ and θ_0. Eq. (4)
IG.pdf	two parameter inverse Gaussian probability density function
$I_0(\alpha,\beta)$	function defined by Eq. (39)
Kt	Coefficient of Kurtosis of a sample of wind speeds
$L(\mathbf{V}, \phi)$	likelihood function of a PDF
LN.pdf	two parameter lognormal probability density function
LSM	least squares method
$m, m'_2, m'_3, \ldots$	low-order statistical moments with respect to the origin of a sample of n wind speeds
m_2,m_3, ...	low-order statistical moments with respect to the mean m of a sample of n wind speeds. Also low-order statistical moments with respect to the mean m of a sample of napierian logarithms of wind speeds. Eq. (8), (9) and (11)
M	number of low-order statistical moments with respect to the origin of a sample of wind speeds
Me	median of a sample of wind speeds
MEP	maximum entropy principle
MLM	maximum likelihood method
MM	moment method
MTNW.pdf	mixture of NT.pdf and W.pdf probability density function
MWW.pdf	two components mixture Weibull probability density function
ME_M.pdf	$M+1$ parameter maximum entropy probability density function
n	number of wind speed data of a sample
N	number of intervals in which the n observed wind speed values of a sample are grouped
NT.pdf	two parameter singly truncated from below normal probability density function
P	a vector which contains the experimental cumulative relative frequencies of wind speeds. Its components are expressed: P_i (i = 1, ..., n) Eq. (1)
PDF	Probability distribution function.
R.pdf	one parameter Rayleigh probability density function
R^2_{wp}	coefficient of determination which indicates the degree of fit between a CDF for wind speed and the cumulative histogram of relative frequency of the cube of hourly mean wind speeds recorded at a given weather station
R^2_{ws}	coefficient of determination which indicates the degree of fit between a CDF for wind speed and the cumulative histogram of relative frequency of hourly mean wind speeds recorded at a given weather station
$R^2_{wp,h}$	coefficient of determination which indicates the degree of fit between a hybrid CDF for wind speed and the cumulative histogram of relative frequency of the cube of hourly mean wind speeds recorded at a given weather station
$R^2_{ws,h}$	coefficient of determination which indicates the degree of fit between a hybrid CDF for wind speed and the cumulative histogram of relative frequency of hourly mean wind speeds recorded at a given weather station
s^2	variance of a sample of n wind speed data
$S(V_{max};\phi)$	non-linear objective function which is to be minimised, Eq. (1)
Sk	coefficient of skewness of a sample of wind speeds
SRN.pdf	two parameter square-root normal probability density function
T_1, T_2 and T_3	Eq. (13)
v_{max}	maximum recorded wind speed of a sample
v_{min}	minimum recorded wind speed of a sample
V	vector which contains the n wind speed data of a sample. Its components are expressed: $v_i (i = 1, \ldots, n)$
$\mathbf{V}_{max}$	a vector which contains the maximum recorded wind speed values within the N intervals in which the n wind speed data of a sample are classified. Its components are expressed: $v_{max,i} (i = 1, \ldots, n)$ Eq. (1)
W.pdf	two parameter Weibull probability distribution function
WECS	wind energy conversion system
$Wp(v,\boldsymbol{\phi},\theta_0)$	PDF of the wind power density. Eq. (5)
X	vector whose components are the napierian logarithms of the components of the vector $\mathbf{V}_{max}$. Eq. (27)
Y	vector which contains data related to the vector **P**. Eq. (27)
$Z(\cdot)$	function defined by Eq. (44)

Greek letters

α	parameter of the PDFs: GG.pdf, W.pdf, SRN.pdf, NT.pdf, LN.pdf, IG.pdf, B.pdf, and MNTW.pdf
α_1, β_1	parameters of one of the two W.pdf which make up the MWW.pdf
α_2, β_2	parameters of one of the two W.pdf which make up the MWW.pdf
β	parameter of the PDFs: GG.pdf, G.pdf, W.pdf, SRN.pdf, NT.pdf, LN.pdf, IG.pdf, B.pdf, and MNTW.pdf
$\Gamma(\cdot)$	gamma function
$\delta(v)$	dirac delta. Eq. (3)
ζ	relation of the two parameters of the NT.pdf. Eq. (43)
η	parameters of the PDFs: GG.pdf and G.pdf
θ	parameter of the R.pdf
θ_0	relative frequency of calms (null wind speeds)
λ	vector which contains the parameters of the ME_M.pdf. The components of this vector are: $\lambda_0, \lambda_1, \ldots, \lambda_M$
μ, σ	parameters of the SRN.pdf
ξ	position parameter of the B.pdf
ϕ	a vector which contains the parameters of a probability density function. Eq. (1)
$1-\phi(\cdot)$	function defined by Eq. (44)
$\psi(\cdot)$	digamma function
$\psi'(\cdot)$	trigamma function
ψ''	tetragamma function
ω	mixture parameter of the mixture distributions MWW.pdf and MNTW.pdf. ($0 \le \omega \le 1$)

frequency histograms of the cube of hourly mean wind speeds recorded at the aforementioned weather stations.

The selected stations present different wind speed frequency histograms, allowing an analysis of the flexibility and usefulness of the collection of models in the description of different wind regimes (high frequencies of null wind speeds, unimodal, bimodal regimes, etc.). The suitability of the distributions is judged from the R^2 statistic (or coefficient of determination) used in various studies [20,42,43,50,47,92,149,153–155,189,201,204,205].

The two parameters of the Weibull (W.pdf) are practically the only ones which, in the literature related to renewable energies, have been estimated making use of different estimation methods [1,2,7,8,11,66,67,70,71,91,114,156–158,162,164,194]. In this paper, however, the three most frequently used estimation methods, namely the moments method (MM), the maximum likelihood method (MLM) and the least squares method (LSM), are applied to the selected collection of PDFs. The aim is to analyse the complexity of the estimation and the goodness of fit to the experimental data in function of the chosen estimation method.

2. Overview of proposed wind speed probability density distributions

In the period from 1940 to 1945, special wind-research programs were carried out in the United States with the aim of investigating potential wind-turbine sites [3]. According to Putnam [3], the experience obtained in the construction of wind speed frequency curves had shown that they were all of a similar type and defined by statistics like Pearson Type III functions. After Putnam [3], who was the first to prospect for sites for large wind turbine generators [2], suggested this probabilistic model, a number of significant models have been proposed to represent wind speed probability density functions. In 1951, Sherlock [4] proposed, like Putnam [3], the use of the Pearson Type III curve (gamma distribution function) of two parameters (scale parameter and shape parameter) arguing that: (a) it had been widely and successfully used in many statistical studies of natural phenomena; (b) graphical studies showed that it gave a reasonably good fit to velocity data; (c) tables were readily available for its use. However, this probability distribution has not been extensively used in the field of wind energy, as the paucity of references testifies to [2,5–11].

For some authors who published their research between 1950 and 1970, and from a viewpoint of statistical theory, it is advantageous to describe the horizontal wind in terms of a bivariate distribution system [2]. Essenwanger [12] showed that the elliptical bivariate distribution of two components was useful for the calculation of upper-air wind speed probabilities. Crutcher and Baer [13] studied the special case of the normal distribution of two variables. These two variables were the horizontal components of the wind speed according to a cartesian axes system. This bivariate distribution depends on the means of the wind speed and the standard deviations in accordance with these axes, and on the normalized correlation coefficient that exists between both variables.

The energy crises of the 1970s, caused by the increase in petrol prices, reactivated interest in renewable energies. This is reflected in the increase in the number of probability models which are proposed during this period. Several authors proposed the use of the bivariate normal distribution with wind speed and direction as variables [14–19]. The distribution law of one variable, derived from this normal law of two variables, comprises a sum of Bessel function products [14]. According to Justus [1] and Koeppl [2], this model is difficult to use for wind energy application given its complicated form and its requirement of five parameters. The isotropic Gaussian model of McWilliams et al. [15,16] and Weber [17] was derived from the assumptions that the wind speed component along the prevailing wind direction (longitudinal component of the wind vector) is normally distributed with non-zero mean and a given variance, while the wind speed component along a direction orthogonal to that (lateral component of wind vector) is independent and normally distributed with zero mean and the same variance. The marginal PDF of the wind speed is obtained after integration over the direction variable [20]. The anisotropic Gaussian model of Weber [18–19] is a generalization of the model of McWilliams et al. [15]. In Weber [18], no restrictions are imposed on the standard deviations of the longitudinal and lateral fluctuations. The marginal PDF of the wind speed is obtained after integration over the direction variable [19,20]. The work carried out in the Canary Archipelago by Carta et al. [20] indicate that the marginal PDFs of wind power density derived from isotropic Gaussian and anisotropic Gaussian models provide, in all cases analysed, low coefficient of determination values.

Winger [21,22] proposed a square-root normal model. This model was based on the hypothesis that the square-root transformation of observed wind speeds can be fitted by a Gaussian distribution centred on the mean of the square-root of the observed speeds. This distribution has had little repercussion on later wind energy analyses [11,23].

Also from the 1970s came the first proposals for the use of wind speed probability distributions of Rayleigh (R.pdf) and Weibull.

The Rayleigh distribution function of one parameter corresponds to the chi distribution for two degrees of freedom. This distribution coincides with the two parameter Weibull distribution when the shape parameter of the latter takes the value 2. The Rayleigh distribution has been widely used, either exclusively [24–27] or sharing centre stage with the Weibull distribution [2,7,8,23,28–60] in numerous wind power studies, including regulatory works [61], due to its simplicity. The W.pdf which had occasionally been used in calculations of the loads exerted by winds on structures [62] began to be used in wind power studies at the end of the 1970s [1,7,28–30,63–68]. The characteristics of the two parameter Weibull distribution have given rise to it becoming the most widely used and accepted probability distribution in the specialised literature on wind energy and other renewable energy sources [8,11,23,31–60,69–185]. Indeed: (a) it is included in regulations concerning wind energy [61]; (b) it forms part of the most popular computer modelling packages, such as HOMER [165–167] and WASP [168–172]; (c) it is practically the only distribution law which is recommended in the present day in books related to wind energy [1,2,60,172–185].

The W.pdf has been employed in various regions of the world fundamentally in the evaluation of wind energy potential; or to be more precise, in the statistical analyses of wind characteristics and wind power density [30–47,69–118]. This distribution has also been used in the construction of a variety of models: (a) estimation of the energy output and capacity factor of wind turbines [119–131], (b) estimation of the performance of autonomous wind energy systems [132–136], (c) variation of wind characteristics with height [137–139], (d) wind speed time series characterisation and stochastic simulation and forecasting of wind speed sequences [138,140–146], (e) bivariate analysis of wind speed and direction [147], (f) wind turbine breakdown analysis [148], etc. A number of questions have been raised that need to be taken into account with the use of the models [149–152]. In order to analyse the behaviour of the W.pdf, comparisons have been performed with certain distribution laws [153–155], and different estimation methods of the parameters on which this distribution depends have been proposed [1,2,156–164].

According to Justus [1] and Koeppl [2], from a practical point of view the two parameter Weibull function is more convenient to use than the univariate Gaussian function and more flexible than the Rayleigh function. It is particularly useful for describing the occurrence of high wind speeds [12]. According to Tuller and Brett [186], the selection of the Weibull distribution can often be attributed to its flexibility, providing a good fit to the observed wind speed distributions, and to the fact that only two parameters are needed for estimation.

The lognormal distribution of two parameters, which in the 1970s had been used by Luna and Church [187] in studies on air pollution and by Kaminsky [7] and Justus et al. [65] in wind speed analyses, has only very exceptionally been proposed for use since then [11,153,188].

Lavagnini et al. [6] used, amongst others, the Pearson Type I function (beta distribution) of three parameters in analyses of wind energy using the wind speed values from 48 meteorological stations of Italian Air Force. Carta et al. [189] used the beta distribution, together with 13 other distributions with the aim of analysing the influence of the degree of fit of a density probability function to wind speed data on the WECS (wind energy conversion system) mean power output estimation.

Due to the fact that the W.pdf has been unable to represent all the wind regimes encountered in nature, researchers have continued to propose new wind speed probability models. These have fundamentally consisted of standard parametric distributions. Takle and Brown [190] proposed the use of what is termed a hybrid density probability function for describing wind speed distributions having non-zero probability of null wind speeds (calms). The method used simply removes those measurements determined to be "calm", and fits the Weibull distribution to the non-zero wind speeds. The zero wind speeds are then reintroduced to give the proper mean and variance and renormalize the distribution. This hybrid distribution has been analysed and employed in various studies [10,186,190–196]. However, Tuller and Bret [186] indicated that in the studies that they carried out in seven stations located on the British Columbia coast, they did not observe in general that the hybrid distribution offered much advantage over the ordinary Weibull distribution, and in many cases produced a worse fit to the observed data.

Stewart and Essenwanger [197] proposed a three parameter variant of the Weibull distribution, where the new parameter is called the location parameter. These authors found the three parameter Weibull distribution to be generally superior to the ordinary two parameter Weibull distribution for estimating certain probability thresholds. However, as pointed out by Chade and Sharma [8], the added location parameter introduces difficulties in the estimation and a positive value for it gives rise to an unrealistic condition of zero probability of wind speeds less than the parameter value.

Auwera et al. [10] proposed the use of the three parameter generalised gamma distribution (GG.pdf) (two shape parameters and one scale parameter) for estimation of mean wind power densities. This distribution is a more general case of the two parameter Weibull distribution [198]. According to these authors, the GG.pdf gave a better fit to observed wind speeds than did a number of other distribution functions.

The inverse Gaussian distribution (IG.pdf)[3] is suggested by Bardsley [199] as a useful alternative to the three parameter Weibull distribution with a positive location parameter for the description of wind speed data with low frequencies of low speeds. According to Bardsley [199], a comparison of the two distributions indicates a region of strong similarity. However, the parameters of the IG.pdf are more difficult to calculate when the maximum likelihood method is used. In addition, according to Bardsley [199], the IG.pdf possesses a number of useful features with respect to wind energy evaluation.

A singly truncated from below normal distribution (NT.pdf) has been used by Carta et al. [189] to describe wind regimes with high probabilities of null wind speeds.

In order to describe wind regimes that present bimodality, various authors have proposed the use of two component mixture distributions. The mixture distributions proposed have comprised mixtures of two W.pdfs [155,175,200–202], mixtures of two normal distributions [203] and mixtures of W.pdf and NT.pdf [20,155]. This latter one, in addition to representing bimodal wind regimes, takes into account null wind speeds.

The use has also been proposed, in the estimation of wind energy, of a general probability distribution obtained through application of the maximum entropy principle (MEP), widely used in various fields of science and engineering, constrained by the low-order statistical moments of a given set of observed hourly mean wind speed data [154,204,205]. These PDFs, besides being able to represent unimodal, bimodal and bitangential winds, take into account the frequencies of null wind speeds [154].

[3] Also called the Wald distribution.

3. Methods used for the estimation of parameters and statistical tests

3.1. Methods used in the estimation of parameters

In order to estimate the parameters[4] of the distribution laws used to describe the characteristics of the wind, various procedures have been adopted.

In most of the studies presented in the specialised literature on wind energy and other renewable energy sources, the parameters are considered from the classical point of view[5]; whilst papers which use a Bayesian approach are few [160].[6] It should also be pointed out that in practically all the studies published in the field of renewable energies, point-based rather than interval-based estimation of the parameters has been carried out [151]. In other words, a search is made for an estimator which, based on the sample data, gives rise to a single-valued estimation of the value of the parameters.

There exist different methods which can be used to find point estimators of parameters with desirable properties [206]. However, the moments method [1–5,7,8,11,30,34,36,38,46,66,67,72,-74,76,91,97,113,114,131,139,154,157,161,164,194,195,200,201,2-03–205], the maximum likelihood method [2,7,8,10,66,70,71,-77,79,91,96,101,105,119,151,153,156,158,162,163,164,189–191,-199,201] and the least squares method [1,2,6,11,20,31,–33,37,39,43,59,47,65–67,70,71,73,75,80–83,85,86,91,92,103,114,–117,150,155–158,161,162,164,186,190,192,194,196,197,201,202] are the ones which have normally been employed in the estimations of the distributions used in statistical analyses of wind.

The moments method consists of equating a certain number of statistical moments of the sample with the corresponding population moments [207]. In this way, a number of equalities are obtained which allow determination of the unknown parameters of the distribution. The estimators obtained through the method of moments are consistent, but not centred, nor with minimum variance nor robust. The advantage of these estimators lies in their simplicity. The drawback is that this method does not use all the information from the sample. According to Canavos [207], the moments method provides a reasonable alternative when estimators of maximum likelihood cannot be determined.

In essence, the maximum likelihood method of estimation selects as estimators those values of the parameters which have the property of maximising the value of the probability of the randomly observed sample [207]. In other words, the maximum likelihood method consists of finding the values of the parameters which maximise the likelihood function. This method provides estimators which are asymptotically centred, have normal asymptotic distribution, and are efficient (asymptotically of minimum variance).

The least squares method provides an alternative to the maximum likelihood method, though it has less optimum desirable properties than the latter [207]. In least squares estimation, the unknown values of the parameters of a probability density function can be estimated by looking for the numerical values of the parameters which minimise the sum of the squares of the deviations between the experimental values and those obtained with the model. Normally, the LSM is applied to the cumulative distribution function $F(v, \boldsymbol{\phi})$. Consider the general optimization problem, to minimise an objective non-linear function $S(\mathbf{V}_{\max};\phi)$ under linear inequality constraints.

$$\mathrm{Min}\, S(\mathbf{V}_{\max};\boldsymbol{\phi}) = \mathrm{Min}\left\{\sum_{i=1}^{N}[\mathbf{P}_i - F(v_{\max,i};\boldsymbol{\phi})]^2\right\} \tag{1}$$

where ϕ is a vector which contains the unknown parameters of the distribution function. $\mathbf{P}$ is a vector that contains the experimental cumulative relative frequencies. In other words, if the observed wind speed values are grouped into N wind speed intervals $0 - v_1, v_1 - v_2, \ldots, v_{N-1} - v_N$ and to each interval is assigned its relative frequency of occurrence fr_1, fr_2, …, fr_N, then the cumulative frequencies will be given by: $P_1 = \mathrm{fr}_1$, $P_2 = P_1 + \mathrm{fr}_2$, $P_N = P_{N-1} + \mathrm{fr}_N$. The vector $\mathbf{V}_{\max}$ contains the maximum recorded wind speed values within each of the N intervals.

The distribution functions reviewed in this paper are not linear. However, those that can be expressed in closed form (Weibull and Rayleigh distributions) are susceptible to linearization. In the case of distribution functions which cannot be linearized, calculation of the parameters which minimise Eq. (1) can be performed through the use of a numerical method, such as that of Levenberg–Marquardt [208].

3.2. Considered statistical decisions

There exist various statistical tests to see whether a sample of wind data comes from a population with a particular probability distribution. However, in statistical analysis of wind the use of goodness of fit tests is not very common. The typically proposed or used goodness of fit tests have been as follows: the Chi-square test [10,42,43,47,92,131,162,194,204,205,209], the Kolmogorov–Smirnov test [101,105,117,157,186] and the Anderson–Darling test [151,106]. However, most often use has been made of a superimposed representation of the histogram of the sample of wind speeds and the fitted PDF to estimate, from a visual comparison, the goodness of fit.

Some authors use the coefficient of determination to measure the goodness of fit on an absolute scale. This coefficient is normally used to measure the linear correlation existing between the cumulative probabilities calculated with the fitted model and with the sample of wind speeds [20,42,43,50,47,92,149,153–155,189,201,204,205,208].

3.3. Notes on the methods and tests used

As pointed out by several authors [145,153,162,210–214], the wind speed recorded at short intervals of time usually presents dependence, and therefore the use of such samples violates the hypotheses on which the estimation techniques and the tests are based. In other words, as indicated by Ramírez and Carta [151], in theory, if the randomness assumption does not hold, then: (a) all of the usual statistical tests are invalid,[7] (b) the calculated uncertainties for commonly used statistics become meaningless and (c) the parameter estimates become suspect and non-supportable.

Ramírez and Carta [151] analysed the influence of the data sampling interval in the estimation of the parameters of the Weibull wind speed probability density distribution. According to them, the use of auto-correlated successive hourly mean wind speeds, though invalidating all of the usual statistical tests, has no significant effect on the shape of the probability density distribution.

[4] The parameters are a numerical characterisation of the population distribution which completely describes the probability density function.

[5] The classical approach supposes that the parameters are unknown fixed amounts about which no relevant initial information is available.

[6] From a Bayesian point of view a parameter is always a random variable with some type of probability distribution.

[7] Though some authors ignore this circumstance [105,106].

4. Review of mathematical/numerical modelling of PDFs

This section of the paper defines the probability density functions, $f(v)$, which have been used in the specialised literature on wind energy and other renewable energy sources. Also shown here is the estimation of the parameters using MM, MLM and LSM. With the aim of analysing the advantages of considering null wind speeds (calms) in the description of wind regimes, use is made of what was called by Takle and Brown [190] the hybrid distribution, $h(v,\boldsymbol{\phi},\theta_0)$. The $h(v,\boldsymbol{\phi},\theta_0)$ are related to the $f(v,\boldsymbol{\phi})$ through Eq. (2). The $h(v,\boldsymbol{\phi},\theta_0)$ are defined in this paper[8] for all the $f(v,\boldsymbol{\phi})$ which do not pick up the frequency of null wind speed.

$$h(v,\boldsymbol{\phi},\theta_0)=\theta_0\delta(v)+(1-\theta_0)f(v,\boldsymbol{\phi}) \tag{2}$$

where, θ_0 is the probability of observation of null wind speed. When $\theta_0=0$ the hybrid distribution $h(v,\boldsymbol{\phi},\theta_0)$ matches the standard distribution $f(v,\boldsymbol{\phi})$. Where $\delta(v)$ is the Dirac operator and is given by the following equation:

$$\delta(v)=\begin{cases}1 & \text{if } v=0\\ 0 & \text{if } v\neq 0\end{cases} \tag{3}$$

The corresponding distribution function $H(v)$ of Eq. (2) is given, according to Takle and Brown [190] by the following equation:

$$H(v,\boldsymbol{\phi},\theta_0)=\begin{cases}\theta_0+(1-\theta_0)F(v,\boldsymbol{\phi}) & \text{if } v\geq 0\\ 0 & \text{if } v<0\end{cases} \tag{4}$$

The PDFs of power density, $\mathrm{wp}(v,\boldsymbol{\phi},\theta_0)$, are obtained from the wind speed probability density functions through the following equation:

$$\mathrm{wp}(v,\boldsymbol{\phi},\theta_0)=\frac{v^3h(v,\boldsymbol{\phi},\theta_0)}{\int_a^b v^3h(v,\boldsymbol{\phi},\theta_0)\mathrm{d}v} \tag{5}$$

where a and b represent the upper and lower bounds of the interval where the function $h(v,\boldsymbol{\phi},\theta_0)$ [202] is defined.

4.1. Three parameter generalised gamma distribution

In accordance with Eq. (2), the hybrid GG.pdf is defined by the following equation:

$$h(v;\alpha,\beta,\eta,\theta_0)=\theta_0\delta(v)+(1-\theta_0)\frac{\alpha v^{\eta-1}}{\beta^{-\eta/\alpha}\Gamma(\eta/\alpha)}\exp[-\beta v^{\alpha}] \tag{6}$$

where α and η are shape factors and $\beta^{-1/\alpha}$ is a scale factor [198]. $\Gamma(\cdot)$is the gamma function of Euler [215]. The cumulative distribution function is given by the following equation:

$$H(v;\alpha,\beta,\eta,\theta_0)=\theta_0+(1-\theta_0)\int_0^v\frac{\alpha v^{\eta-1}}{\beta^{-\eta/\alpha}\Gamma(\eta/\alpha)}\exp[-\beta v^{\alpha}]\,\mathrm{d}v \tag{7}$$

4.1.1. Moment estimates of the parameters

In order to carry out the estimation of the three parameters of the generalised gamma distribution, we propose in this paper the use of the method suggested by Stacy and Mihram [216], which is based on the use of the first moments of the variable ln V.

Through the use of Eq. (8)[9] the relation η/α is determined. In Eq. (8) m_2 and m_3 are the variance and the third moment with respect to the mean of the napierian logarithms of the sample data and, therefore, null wind speeds are not considered. $\psi'(\eta/\alpha)$ is the trigamma function and $\psi''(\eta/\alpha)$ is the tetragamma function [215]. Eq. (7) can be resolved using a combination of the bisection method and the Newton–Raphson method [217].

$$\frac{m_3}{(m_2)^{3/2}}=\frac{\psi''(\eta/\alpha)}{[\psi'(\eta/\alpha)]^{3/2}} \tag{8}$$

Once the relation η/α is determined, the parameter α is obtained from the following equation:

$$\alpha=\frac{m_2}{m_3}\frac{\psi''(\eta/\alpha)}{\psi'(\eta/\alpha)} \tag{9}$$

Once η/α and α are known, the parameter η is obtained from the following equation:

$$\eta=\left(\frac{\eta}{\alpha}\right)\alpha \tag{10}$$

The parameter β is deduced from Eq. (11), where $\psi(\eta/\alpha)$ is the digamma function [215] and m is the mean of the napierian logarithms of the sample data

$$\beta=\exp\left[\psi\left(\frac{\eta}{\alpha}\right)-m\alpha\right] \tag{11}$$

4.1.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [218] Eq. (12) can be obtained:

$$\alpha T_3-\ln[\alpha(T_2-T_1T_3)]-\psi\left[\frac{T_1}{\alpha(T_2-T_1T_3)}\right]=0 \tag{12}$$

where

$$T_1=n^{-1}\sum_{i=1}^{n}(v_i)^{\alpha}\qquad T_2=n^{-1}\sum_{i=1}^{n}(v_i)^{\alpha}\ln(v_i)$$
$$T_3=n^{-1}\sum_{i=1}^{n}\ln(v_i) \tag{13}$$

In order to determine α Eq. (12) can be resolved using a combination of the bisection method and the Newton–Raphson method [217]. Then β and η are determined through the following equation:

$$\beta=\frac{1}{\alpha(T_2-T_1T_3)},\qquad \eta=\frac{T_1}{T_2-T_1T_3} \tag{14}$$

4.2. Two parameter gamma distribution

In accordance with Eq. (2), the hybrid G.pdf is defined by the following equation:

$$h(v;\beta,\eta,\theta_0)=\theta_0\delta(v)+(1-\theta_0)\frac{v^{\eta-1}}{\beta^{\eta}\Gamma(\eta)}\exp[-v/\beta] \tag{15}$$

The G.pdf is a particular case of the GG.pdf.

[8] According to the information available to the authors of this work, with the exception of Auwera et al. [10], the hybrid distribution of Takle and Brown [190] was exclusively generated with the two parameter Weibull distribution. Auwera et al. [10] propose the construction of hybrid distributions with lognormal and three parameter gamma generalised laws (hypergamma, modified gamma, Weibull three-parameter [10]) and laws derived from the latter: two parameter Weibull, one parameter Rayleigh, two parameter gamma (Pearson-type III), one parameter exponential and one parameter Chi-squared. Auwera et al. [10] estimate the parameters using the maximum likelihood method and check the goodness of fits using the χ^2-test.

[9] As can be seen, the parameters calculated with this procedure do not pick up the periods of null wind speeds.

The cumulative distribution function is given by the following equation:

$$H(v;\beta,\eta,\theta_0)=\theta_0+(1-\theta_0)\int_0^v \frac{v^{\eta-1}}{\beta^\eta\Gamma(\eta)}\exp\left[-\frac{v}{\beta}\right]\mathrm{d}v \tag{16}$$

4.2.1. Moment estimates of the parameters

In order to carry out the estimation of the two unknown parameters, the mean and variance of the W.pdf [219] are equated to the corresponding values of the sample[10] (m and s^2). From the resolution of the proposed system of two equations the estimated values of the parameters are obtained (Eq. (17))

$$\beta=\frac{s^2}{m},\qquad \eta=\frac{m^2}{s^2} \tag{17}$$

4.2.2. Maximum likelihood of the parameters

Operating with the maximum likelihood function [219] Eq. (18) can be obtained

$$\ln(\eta)-\psi(\eta)=\ln\left(\frac{\sum_{i=1}^n v_i}{\sum_{i=1}^n \ln(v_i)}\right) \tag{18}$$

Eq. (18) can be resolved using a combination of the bisection method and the Newton–Raphson method [217].

Once parameter η is determined that satisfies Eq. (18), parameter β is obtained from the following equation:

$$\beta=\frac{1}{n\eta}\sum_{i=1}^n(v_i) \tag{19}$$

4.3. Two parameter Weibull distribution

In accordance with Eq. (2), the hybrid W.pdf is defined by the following equation:

$$h(v;\alpha,\beta,\theta_0)=\theta_0\delta(v)+(1-\theta_0)\left(\frac{\alpha}{\beta}\right)\left(\frac{v}{\beta}\right)^{\alpha-1}\exp\left[\left(\frac{-v}{\beta}\right)^\alpha\right] \tag{20}$$

The cumulative distribution function is given by the following equation:

$$H(v;\alpha,\beta,\theta_0)=\theta_0+(1-\theta_0)\left[1-\exp\left[-\left(\frac{v}{\beta}\right)\right]^\alpha\right] \tag{21}$$

4.3.1. Moment estimates of the parameters

In order to carry out the estimation of the two unknown parameters, the mean and variance of the W.pdf [219] are equated to the corresponding values of the sample[11] (m and s^2). From the resolution of the proposed system of two equations the estimated values of the parameters are obtained.[12] According to the authors of this paper, the shape parameter α can be estimated through the approximate expression given by the following equation:

$$\alpha=\left(\frac{s}{m}\right)^{-1.091} \tag{22}$$

The scale parameter β is determined from the following equation [1]:

$$\beta=\frac{m}{\Gamma(1+1/\alpha)} \tag{23}$$

4.3.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [219] Eq. (24) can be obtained:

$$\alpha=\left[\frac{\sum_{i=1}^n v_i^\alpha\ln v_i}{\sum_{i=1}^n v_i^\alpha}+\frac{1}{n}\sum_{i=1}^n\ln(v_i)\right]^{-1} \tag{24}$$

In order to estimate α, Eq. (24) can be resolved using an iterative procedure. Parameter β is determined from the following equation:

$$\beta=\left(\frac{1}{n}\sum_{i=1}^n(v_i)^\alpha\right)^{1/\alpha} \tag{25}$$

4.3.3. Least square estimates of the parameters

The shape parameter α, as shown by Justus et al. [67], can be estimated through the following equation:

$$\alpha=\left\{N\sum_{i=1}^N Y_iX_i-\left(\sum_{i=1}^N X_i\right)\left(\sum_{i=1}^N Y_i\right)\right\}\left\{N\sum_{i=1}^N X_i^2-\left(\sum_{i=1}^N X_i\right)^2\right\}^{-1} \tag{26}$$

where

$$Y_i=\ln\{-\ln[1-P_i]\}\qquad X_i=\ln v_{\max,i} \tag{27}$$

In Eq. (27), the P_i are the components of the vector **P**, which contains the experimental cumulative relative frequencies of the N intervals in which the n wind speeds of the sample have been classified. $v_{\max,i}$ are the maximum recorded wind speed values within each of the N intervals (see Section 3.1). The scale parameter β is estimated from the following equation:

$$\beta=\exp\left[-\frac{k}{\alpha}\right] \tag{28}$$

where k is estimated through the following equation:

$$k=\left\{\sum_{i=1}^N Y_i\sum_{i=1}^N X_i^2-\left(\sum_{i=1}^N X_i\right)\left(\sum_{i=1}^N X_iY_i\right)\right\}\left\{N\sum_{i=1}^N X_i^2-\left(\sum_{i=1}^N X_i\right)^2\right\}^{-1} \tag{29}$$

4.4. One parameter Rayleigh distribution

In accordance with Eq. (2), the hybrid R.pdf is defined by the following equation:

$$h(v;\theta,\theta_0)=\theta_0\delta(v)+(1-\theta_0)\left(\frac{v}{\theta^2}\right)\exp\left[-\left(\frac{v}{\sqrt{2\theta}}\right)^2\right] \tag{30}$$

The R.pdf is a particular case of the W.pdf when $\alpha=2$. The cumulative distribution function is given by the following equation:

$$H(v;\theta,\theta_0)=\theta_0+(1-\theta_0)\left[1-\mathrm{e}^{-v^2/(2\theta^2)}\right] \tag{31}$$

[10] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[11] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[12] Another method which could be catalogued as a moments method, and which has also been proposed for estimation of the shape parameter α, consists of equating the so-called energy pattern factor [2,66,176–178] or cube factor [2,4] of the PDF with the corresponding factor of the wind speed data sample. The cube factor describes the ratio of the mean of wind speed cubed to the cube of the mean wind speed. Once α is estimated, the scale parameter β is estimated using Eq. (23).

4.4.1. Moment estimator of the parameter

In order to carry out the estimation of the unknown parameter, the mean of the distribution is equated [219] to the corresponding mean of the distribution of the sample[13] (m). From this equality the parameter θ is obtained, Eq. (32)

$$\theta = \frac{\sqrt{2}}{\sqrt{\pi}} m \tag{32}$$

4.4.2. Maximum likelihood estimator of the parameter

Operating with the maximum likelihood function [219], Eq. (33) can be obtained, which enables estimation of θ

$$\theta = \left(\frac{1}{2n} \sum_{i=1}^{n} (v_i)^2 \right)^{1/2} \tag{33}$$

4.4.3. Least square estimator of the parameter

The parameter θ can be estimated through the following equation:

$$\theta = \left\{ \frac{1}{2} \exp\left[-\frac{1}{N} \left(\sum_{i=1}^{N} Y_i - 2\sum_{i=1}^{N} X_i \right) \right] \right\}^{1/2} \tag{34}$$

where X_i and Y_i are given by Eq. (27).

4.5. Two parameter square-root normal distribution (SRN.pdf)

In accordance with Eq. (2), the hybrid SRN.pdf is defined by the following equation:

$$h(v;\mu,\sigma,\theta_0) = \theta_0 \delta(v) + (1-\theta_0) \frac{1}{\sigma\sqrt{8\pi v}} \exp\left[\frac{-(\sqrt{v}-\mu)^2}{2\sigma^2} \right] \tag{35}$$

where μ and σ are the mean and standard deviation of the distribution.

The cumulative distribution function is given by the following equation:

$$H(v;\mu,\sigma,\theta_0) = \theta_0 + (1-\theta_0) \int_0^{\infty} \frac{1}{\sigma\sqrt{8\pi v}} \exp\left[\frac{-(\sqrt{v}-\mu)^2}{2\sigma^2} \right] \mathrm{d}v \tag{36}$$

4.5.1. Moment estimates of the parameters

In this case, the mean and variance of the SRN.pdf distribution are equated to the corresponding values of the sample[14] (m and s^2).

$$\mu = m = \frac{\sum_{i=1}^{n} v_i^{1/2}}{n}, \qquad \sigma^2 = s^2 = \frac{\sum_{i=1}^{n} \left(v_i^{1/2} - m\right)^2}{n} \tag{37}$$

4.5.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function, the equalities shown in Eq. (37) are obtained as a result.

4.6. Two parameter normal truncated distribution (NT.pdf)

The singly truncated from below normal distribution is defined by the following equation [155,198]:

$$f(v;\alpha,\beta) = \frac{1}{I_0(\alpha,\beta)\beta\sqrt{2\pi}} \exp\left[\frac{-(v-\alpha)^2}{2\beta^2} \right] \tag{38}$$

where $I_0(\alpha,\beta)$ is expressed by the following equation:

$$I_0(\alpha,\beta) = \frac{1}{\beta\sqrt{2\pi}} \int_0^{\infty} \exp\left[\frac{-(v-\alpha)^2}{2\beta^2} \right] \mathrm{d}v \tag{39}$$

The cumulative distribution function is given by the following equation:

$$F(v;\alpha,\beta) = \int_0^{v} \frac{1}{I_0(\alpha,\beta)\beta\sqrt{2\pi}} \mathrm{e}^{-(v-\alpha)^2/(2\beta^2)} \mathrm{d}v \tag{40}$$

4.6.1. Moment estimates of the parameters

In order to carry out estimation of the two unknown parameters (α and β) of the distribution, the first three statistical moments of the sample with respect to the origin (m, m_2', m_3')[15] can be used. These are equated to the first three moments with respect to the origin of the distribution, as proposed by Cohen [220]. As shown by Cohen [220], the following expressions are obtained of the estimated parameters, Eq. (41)

$$\alpha = \frac{2m_2'm - m_3'}{2m^2 - m_2'}, \qquad \beta^2 = \frac{mm_3' - m_2'^2}{2m^2 - m_2'} \tag{41}$$

4.6.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [198] Eq. (42) can be obtained

$$\left[\frac{Z(\zeta)}{1-\phi(\zeta)} - \zeta \right]^{-1} \left\{ \left[\frac{Z(\zeta)}{1-\phi(\zeta)} - \zeta \right]^{-1} - \zeta \right\} = \frac{1}{n(m)^2} \sum_{i=1}^{n} v_i^2 \tag{42}$$

where

$$\zeta = -\frac{\alpha}{\beta} \tag{43}$$

$$Z(\zeta) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{\zeta^2}{2} \right], \qquad 1-\phi(\zeta) = \frac{1}{\sqrt{2\pi}} \int_0^{\zeta} \exp\left[-\frac{x^2}{2} \right] \mathrm{d}x \tag{44}$$

Eq. (42) is known as the Pearson–Lee–Fisher equation [220], and can be resolved, to determine ζ, using a combination of the bisection method and the Newton–Raphson method [217]. β is estimated with Eq. (45) and α with Eq. (43)

$$\beta = \left(\frac{Z(\zeta)}{1-\phi(\zeta)} - \zeta \right)^{-1} m \tag{45}$$

[13] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[14] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[15] The singly truncated from below normal distribution takes into account null wind speeds. Therefore, the three moments with respect to the origin of the sample pick up all the wind speed values, including null wind speeds.

4.7. Two parameter lognormal distribution (LN.pdf)

In accordance with Eq. (2), the hybrid LN.pdf is defined by the following equation:

$$h(v;\alpha,\beta,\theta_0) = \theta_0\delta(v) + (1-\theta_0)\frac{1}{v\beta\sqrt{2\pi}}\exp\left\{-\frac{1}{2}\left[\frac{\ln(v)-\alpha}{\beta}\right]^2\right\} \tag{46}$$

The standard LN.pdf depends on two parameters (α and β) [219] and does not take into account null wind speeds. The cumulative distribution function is given by the following equation:

$$H(v;\alpha,\beta,\theta_0) = \theta_0 + (1-\theta_0)\int_{>0}^{v}\frac{1}{v\beta\sqrt{2\pi}}\,\mathrm{e}^{-\{(1/2)[(\ln(v)-\alpha)/\beta]^2\}}\,\mathrm{d}v \tag{47}$$

4.7.1. Moment estimates of the parameters

In order to carry out the estimation of the two unknown parameters of the distribution, the sample mean and variance[16] can be equated to the mean and variance of the distribution. Resolving the resulting system of two equations with two unknowns, the estimated values of α and β are obtained, Eq. (48).

$$\alpha = \ln\left[\frac{m}{\sqrt{1+(s^2/m^2)}}\right], \qquad \beta = \sqrt{\ln\left[1+\frac{s^2}{m^2}\right]} \tag{48}$$

4.7.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [219], Eq. (49) can be obtained, which enables estimation of the values of the parameters α and β.

$$\alpha = \frac{1}{n}\sum_{i=1}^{n}\ln(v_i), \qquad \beta^2 = \frac{1}{n}\sum_{i=1}^{n}[\ln(v_i)-\alpha]^2 \tag{49}$$

4.8. Two parameter inverse Gaussian distribution

In accordance with Eq. (2), the hybrid GI.pdf is defined by the following equation:

$$h(v;\alpha,\beta,\theta_0) = \theta_0\delta(v) + (1-\theta_0)\left(\frac{\beta}{2\pi v^3}\right)^{1/2}\exp\left[-\frac{\beta(v-\alpha)^2}{2v\alpha^2}\right] \tag{50}$$

The standard IG.pdf depends on two parameters (α and β) [198] and does not take into account null wind speeds. The cumulative distribution function is given by the following equation:

$$H(v;\alpha,\beta,\theta_0) = \theta_0 + (1-\theta_0)\int_0^v\left[\frac{\beta}{2\pi v^3}\right]^{1/2}\exp\left[-\frac{\beta(v-\alpha)^2}{2v\alpha^2}\right]\mathrm{d}v \tag{51}$$

4.8.1. Moment estimates of the parameters

In order to carry out the estimation of the two unknown parameters (α and β) of the distribution, the sample mean and variance (m, s^2)[17] can be equated to the mean and variance of the distribution. Resolving the resulting system of two equations with two unknowns, the estimated values of α and β are obtained, Eq. (52).

$$\alpha = m, \qquad \beta = \frac{m^3}{s^2} \tag{52}$$

4.8.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [219] the values of the parameters α and β can be obtained, Eq. (53).

$$\alpha = \frac{1}{n}\sum_{i=1}^{n}v_i, \qquad \beta = n\left\{\sum_{i=1}^{n}v_i^{-1} - n^2\left(\sum_{i=1}^{n}(v_i)\right)^{-1}\right\}^{-1} \tag{53}$$

4.9. Three parameter beta distribution (B.pdf)

In accordance with Eq. (2), the hybrid B.pdf is defined by the following equation:

$$h(v;\alpha,\beta,\xi,\theta_0) = \theta_0\delta(v) + (1-\theta_0)\frac{1}{\xi}\frac{1}{B(\alpha,\beta)}\left(\frac{v}{\xi}\right)^{\alpha-1}\left(\frac{\xi-v}{\xi}\right)^{\beta-1} \tag{54}$$

where $B(\alpha,\beta)$ is the beta function of Euler [215], α and β are the shape parameters (both positive), and ξ is a position parameter [219]. The cumulative distribution function is given by the following equation:

$$H(v;\alpha,\beta,\xi,\theta_0) = \theta_0 + (1-\theta_0)\int_0^v\frac{1}{\xi}\frac{1}{B(\alpha,\beta)}\left(\frac{v}{\xi}\right)^{\alpha-1}\left(\frac{\xi-v}{\xi}\right)^{\beta-1}\mathrm{d}v \tag{55}$$

4.9.1. Moment estimates of the parameters

In order to carry out the estimation of the three parameters (α, β and ξ) of the B.pdf the first three statistical moments of the sample can be equated to the corresponding first three moments of the distribution [219]. As a result of this procedure a non-linear system equation has to be solved.[18] However, in this paper it is proposed that the first and second moment of the distribution are equated to the corresponding moments of the sample (m, m_2'). The parameter ξ is directly estimated, equating it to the maximum value of the speed ($v_{\max}$) of the sample. This entails considering that the probability that wind speeds greater than $v_{\max}$ occur in the population is null. The larger the size of the sample the greater the validity of this hypothesis.

$$\xi = v_{\max}, \qquad \alpha = \frac{1}{\xi}\left(\frac{m^2\xi - mm_2'}{m_2'-m^2}\right), \qquad \beta = \left(\frac{m\xi - m_2'}{m_2'-m^2}\right) - \alpha \tag{56}$$

4.9.2. Maximum likelihood estimates of the parameters

Operating with the maximum likelihood function [219] we can obtain Eq. (57). The resolution of the non-linear system of equations Eq. (57) enables estimation of the values of the parameters α and β.

$$\begin{aligned}\psi(\beta) - \psi(\alpha+\beta) &= \frac{1}{n}\sum_{i=1}^{n}\ln\left[1 - v_i\exp\left[\psi(\alpha)-\psi(\alpha+\beta)-\frac{1}{n}\sum_{i=1}^{n}\ln v_i\right]; \frac{\alpha+\beta-1}{\beta-1}\right. \\ &= \frac{1}{n}\sum_{i=1}^{n}\left[1 - v_i\exp\left[\psi(\alpha)-\psi(\alpha+\beta)-\frac{1}{n}\sum_{i=1}^{n}\ln v_i\right]\right]^{-1}\end{aligned} \tag{57}$$

[16] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[17] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

[18] The experience of the authors of this paper is that these solutions usually result in the restriction imposed on the position parameter $\xi \geq v_{\max}$ not being met.

Table 1
Descriptive numerical measurements of the four weather stations analysed

Weather stations	Geographical coordinates		Height (m)	Years	Mean, m (m s^{-1})	Variance, s^2 (m^2 s^{-2})	Calms, θ_0 (%)	Maximum, v_{max} (m s^{-1})	Skewness, Sk	Kurtosis, Kt	Median, Me (m s^{-1})
	Latitude	Length									
La Palma	28°37′13″N	17°45′13.1W	10	2003–2005	4.61	4.55	6.615×10^{-3}	22.00	0.55	3.89	4.20
Granadilla	28°4′5.7″N	16°30′26.3″W	10	1998–2000, 2002, 2004	6.95	15.04	1.439×10^{-3}	19.8	0.254	2.12	6.80
P. Gorra	27°57′36″N	15°33′35″W	20	2005–2007	6.40	18.09	0.014	32.3	0.946	3.93	5.80
Amagro	28°7′58.9″N	15°40′55″W	20	1997–1999, 2001–2003, 2005, 2007	7.89	15.11	4.625×10^{-3}	24.30	0.115	2.48	8.0

The parameter ξ is then estimated using the following equation:

$$\xi = \exp\left[\psi(\alpha+\beta) - \psi(\alpha) + \frac{1}{n}\sum_{i=1}^{n}\ln v_i\right] \tag{58}$$

4.10. Two components mixture Weibull distribution (MWW.pdf)

In accordance with Eq. (2), the hybrid MWW.pdf is defined by the following equation:

$$\begin{aligned} h(v;\alpha_1,\beta_1,\alpha_2,\beta_2,\omega,\theta_0) &= \theta_0\delta(v) + (1-\theta_0)\left\{\frac{\omega\alpha_1}{\beta_1(v/\beta_1)^{\alpha_1-1}}\exp\left[\left(\frac{-v}{\beta_1}\right)^{\alpha_1}\right]\right. \\ &\left. + (1-\omega)\frac{\alpha_2}{\beta_2(v/\beta_2)^{\alpha_2-1}}\exp\left[\left(\frac{-v}{\beta_2}\right)^{\alpha_2}\right]\right\} \end{aligned} \tag{59}$$

where $0 \le \omega \le 1$ is a mixture parameter, α_1 and α_2 are shape parameters and β_1 and β_2 are scale parameters.

The cumulative distribution function is given by the following equation:

$$\begin{aligned} H(v;\alpha_1,\beta_1,\alpha_2,\beta_2,\omega,\theta_0) = \theta_0 + (1-\theta_0)[\omega[1-\mathrm{e}^{-(v/\beta_1)^{\alpha_1}}] \\ + (1-\omega)[1-\mathrm{e}^{-(v/\beta_2)^{\alpha_2}}]] \end{aligned} \tag{60}$$

4.10.1. Moment estimates of the parameters

In order to estimate the five parameters of the hybrid MWW.pdf, the first five statistical moments of the theoretical distribution are equated to the corresponding moments of the sample, $m'_r (r = 1,\ldots,5)$.[19]

$$m'_r = \omega\beta_1^r\Gamma\left(1+\frac{r}{\alpha_1}\right) + (1-\omega)\beta_2^r\Gamma\left(1+\frac{r}{\alpha_2}\right) \tag{61}$$

The system of Eq. (61) does not have an analytical solution. In this paper we propose the use of a Quasi–Newton algorithm [217] to numerically resolve this system of equations. However, it should be pointed out that there are, in general, a number of potential problems related to the application of the method of moments in mixture distributions [221].

4.10.2. Maximum likelihood estimates of the parameters

In order to find the values of the parameters (α_1, β_1, α_2, β_2 and ω) the likelihood function or the logarithm of the likelihood function has to be maximised, Eq. (62).

$$\begin{aligned} &\text{maximizar} \ln L(v_i;\alpha_1,\beta_1,\alpha_2,\beta_2,\omega) \\ &= \sum_{i=1}^{m}\ln\left\{\omega\left[\frac{\alpha_1}{\beta_1}\left(\frac{v_i}{\beta_1}\right)^{\alpha-1}\exp\left[-\left(\frac{v_i}{\beta_1}\right)^{\alpha_1}\right]\right]\right. \\ &\left. + (1-\omega)\left[\frac{\alpha_2}{\beta_2}\left(\frac{v_i}{\beta_2}\right)^{\alpha_2-1}\exp\left[-\left(\frac{v_i}{\beta_2}\right)^{\alpha_2}\right]\right]\right\} \end{aligned} \tag{62}$$

Various numerical methods have been proposed to resolve Eq. (62) [221]. Amongst the most familiar should be mentioned the Newton–Raphson method (NR), the Scoring method (SM) and the expectation-maximization (EM) algorithm. Each of these has a series of advantages and drawbacks [221].

4.11. Singly truncated normal Weibull mixture distribution (MTNW.pdf)

In accordance with Ref. [155] the MTNW.pdf is defined by the following equation:

$$\begin{aligned} f(v;\alpha_1,\beta_1,\alpha,\beta,\omega) &= \frac{\omega\alpha_1}{\beta_1(v/\beta_1)^{\alpha_1-1}}\exp\left[\left(\frac{-v}{\beta_1}\right)^{\alpha_1}\right] \\ &+ (1-\omega)\frac{1}{I_0(\alpha,\beta)\beta\sqrt{2\pi}}\exp\left[\frac{-(v-\alpha)^2}{2\beta^2}\right] \end{aligned} \tag{63}$$

where $I_0(\alpha,\beta)$is expressed by Eq. (39).

The cumulative distribution function is given by the following equation:

$$\begin{aligned} F(v;\alpha_1,\beta_1,\alpha,\beta,\omega) &= \omega[1-\mathrm{e}^{-(v/\beta_1)^{\alpha_1}}] \\ &+ (1-\omega)\int_0^v \frac{1}{I_0(\alpha,\beta)\beta\sqrt{2\pi}}\exp\left[\frac{-(v-\alpha)^2}{2\beta^2}\right]\mathrm{d}v \end{aligned} \tag{64}$$

4.11.1. Moment estimates of the parameters

In order to estimate the five parameters (α, β, α_1, β_1 and ω) of the MTNW.pdf the first five statistical moments of the theoretical distribution are equated to the corresponding moments of the sample $m'_r (r = 1,\ldots,5)$.

$$\begin{aligned} m'_r = \omega\beta_1^r\Gamma\left(1+\frac{r}{\alpha_1}\right) + (1-\omega) + (1 \\ -\omega)\int_0^\infty \frac{v^r}{I_0(\alpha,\beta)\beta\sqrt{2\pi}}\exp\left[\frac{-(v-\alpha)^2}{2\beta^2}\right]\mathrm{d}v \end{aligned} \tag{65}$$

The system of Eq. (65) can be resolved using the techniques indicated in Section 4.10.1

4.11.2. Maximum likelihood estimates of the parameters

In order to find the values of the parameters (α, β, α_1 β_1 and ω) the likelihood function or the logarithm of the likelihood function has to be maximised, Eq. (66).

[19] Once the null wind speeds are eliminated, if dealing with the hybrid distribution. With all the values, if dealing with the standard distribution.

Table 2
La Palma weather station

Method	GG.pdf			G.pdf		W.pdf		NT.pdf		WW.pdf					R.pdf	B.pdf			NR.pdf		IG.pdf		LN.pdf		WNT.pdf				
	α	β	η	β	η	α	β	α	β	α_1	β_1	α_2	β_2	ω	θ	α	β	ξ	μ	σ	α	β	α	β	α	β	α_1	β_1	ω
MM	1.7792	0.0918	2.8642	0.955	4.861	2.316	5.241	4.457	2.338	3.159	5.391	1.624	4.803	0.651	3.705	3.638	13.599	22	2.097	0.495	4.644	22.575	1.442	0.433	3.861×10^{-6}	5.22	2.801	5.303	0.184
ML	1.812	0.083	2.817	1.06	4.383	2.343	5.244	4.48	2.272	2.401	5.222	3.083	13.478	0.9973	3.605	3.671	16.729	25.788	2.097	0.495	4.644	14.748	1.417	0.519	0	5.355	2.492	5.252	0.079
LS	2.369	0.018	1.991	1.165	3.822	2.128	4.942	4.08	2.378	2.249	2.995	2.977	5.851	0.34	3.491	3.45	16.751	25.77	2.029	0.54	4.536	16.403	1.387	0.505	4.871	2.124	2.428	2.851	0.75

Parameters of the standard probability density distributions (PDFs) estimated with moments (MM), maximum likelihood (ML) and least square (LS) methods.

Table 3
Granadilla weather station Parameters of the standard probability density functions (PDFs) estimated with moments (MM), maximum likelihood (ML) and least square (LS) methods

Method	GG.pdf			G.pdf		W.pdf		NT.pdf		WW.pdf					R.pdf	B.pdf			NR.pdf		IG.pdf		LN.pdf		WNT.pdf				
	α	β	η	β	η	α	β	α	β	α_1	β_1	α_2	β_2	ω	θ	α	β	ξ	μ	σ	α	β	α	β	α	β	α_1	β_1	ω
MM	4.3848	1.4251×10^{-5}	1.2438	2.155	3.228	1.937	7.845	6.243	4.417	3.241	9.995	2.109	3.247	0.671	5.551	1.823	3.418	20	2.529	0.749	6.958	22.46	1.805	0.519	3.02	1.752	3.474	10.335	0.375
ML	4.752	5.313×10^{-6}	1.281	2.832	2.457	1.831	7.812	6.168	4.523	2.102	3.521	3.434	10.235	0.3692	5.63	2.433	166.988	484.031	2.529	0.749	6.958	7.915	1.723	0.752	2.852	1.463	3.335	10.148	0.341
LS	4.295	1.676×10^{-5}	1.196	2.749	2.626	1.759	7.981	5.897	4.948	2.241	3.37	3.35	10.106	0.351	5.68	1.612	2.947	19.8	2.536	0.827	7.409	17.388	1.819	0.616	2.811	1.453	3.317	10.119	0.34

Table 4
P. Gorra weather station

Method	GG.pdf			G.pdf		W.pdf		NT.pdf		WW.pdf					R.pdf	B.pdf			NR.pdf		IG.pdf		LN.pdf		WNT.pdf				
	α	β	η	β	η	α	β	α	β	α_1	β_1	α_2	β_2	ω	θ	α	β	ξ	μ	σ	α	β	α	β	α	β	α_1	β_1	ω
MM	1.6161	0.0386	1.5415	4.861	0.955	1.576	7.224	3.651	6.022	1.863	8.649	1.265	5.056	0.574	5.175	1.702	7.173	33.823	2.4	0.851	6.486	15.366	1.694	0.593	3.176	6.705	2.192	5.95	0.741
ML	1.323	0.105	1.768	3.0	2.162	1.589	7.242	3.96	5.804	1.085	4.696	1.589	7.242	0	5.47	1.885	10.998	44.337	2.4	0.851	6.486	7.997	1.621	0.771	3.881	6.544	1.949	5.724	0.678
LS	1.604	0.04	1.528	3.009	2.18	1.559	7.187	4.076	5.555	1.493	6.361	1.789	8.59	0.629	5.1	1.862	11.002	44.741	2.381	0.861	6.764	13.049	1.693	0.67	2.406	4.225	1.759	8.642	0.428

Parameters of the standard probability density distributions (PDFs) estimated with moments (MM), maximum likelihood (ML) and least square (LS) methods.

Table 5
Amagro weather station

Method	GG.pdf			G.pdf		W.pdf		NT.pdf		WW.pdf					R.pdf	B.pdf			NR.pdf		IG.pdf		LN.pdf		WNT.pdf				
	α	β	η	β	η	α	β	α	β	α_1	β_1	α_2	β_2	ω	θ	α	β	ξ	μ	σ	α	β	α	β	α	β	α_1	β_1	ω
MM	4.47	1.0162×10^{-5}	1.5402	1.879	4.218	2.231	8.949	7.557	4.166	3.19	10.642	1.723	5.973	0.619	6.324	2.683	5.668	24.668	2.4	0.851	6.486	15.366	1.694	0.593	3.176	6.705	2.192	5.95	0.741
ML	4.23	1.953×10^{-5}	1.541	2.722	2.911	2.106	8.896	7.525	4.241	1.451	5.453	3.074	10.299	0.3007	6.233	2.878	146.079	409.754	2.728	0.696	7.926	8.643	1.889	0.719	5.944	4.537	3.7	11.08	0.654
LS	4.753	4.87×10^{-6}	1.538	2.089	3.924	2.171	9.093	7.541	4.32	1.568	6.668	3.491	10.567	0.456	6.417	2.719	6.061	26.013	2.755	0.728	8.35	31.451	2.002	0.496	2.536	2.179	2.987	10.115	0.194

Parameters of the standard probability density functions (PDFs) estimated with moments (MM), maximum likelihood (ML) and least square (LS) methods.

Table 6
Parameters of the maximum entropy probability density distributions (1: La Palma; 2: Granadilla; 3: P. Gorra; 4: Amagro)

	ME_5.pdf						ME_2.pdf			ME_4.pdf					ME_3.pdf			
	λ_0	λ_1	λ_2	λ_3	λ_4	λ_5	λ_0	λ_1	λ_2	λ_0	λ_1	λ_2	λ_3	λ_4	λ_0	λ_1	λ_2	λ_3
1	−3.358	0.78	−0.099	6.927×10^{-4}	3.431×10^{-5}	1.183×10^{-6}	−3.659	0.868	−0.097	−3.494	0.831	−0.103	7.375×10^{-4}	3.353×10^{-5}	−3.96	1.148	−0.162	4.147×10^{-3}
2	−2.946	0.155	−0.017	7.959×10^{-4}	-3.509×10^{-6}	-3.151×10^{-6}	−3.257	0.297	−0.024	−2.9	0.088	2.077×10^{-4}	-1.708×10^{-4}	-4.279×10^{-5}	−2.965	0.105	4.541×10^{-3}	-1.157×10^{-3}
3	−2.657	0.144	−0.018	5.769×10^{-5}	2.321×10^{-6}	1.183×10^{-6}	−2.626	0.118	−0.015	−2.575	0.112	−0.016	5.241×10^{-5}	2.082×10^{-6}	−3.554	0.224	-1.323×10^{-3}	-9.982×10^{-4}
4	−3.649	0.292	−0.014	-1.742×10^{-4}	-9.802×10^{-6}	-3.872×10^{-7}	−3.898	0.418	−0.028	−3.601	0.264	−0.01	-2.952×10^{-4}	−3.601	−3.554	0.224	-1.323×10^{-3}	-9.982×10^{-4}

$$\begin{aligned}&\text{maximizar} \ln L(v_i;\alpha_1,\beta_1,\alpha,\beta,\omega)\\&=\sum_{i=1}^{n}\ln\left\{\omega\left[\frac{\alpha_1}{\beta_1}\left(\frac{v_i}{\beta_1}\right)^{\alpha-1}\exp\left[-\left(\frac{v_i}{\beta_1}\right)^{\alpha_1}\right]\right]\right.\\&\left.+(1-\omega)\left[\frac{1}{I_0(\alpha,\beta)\beta\sqrt{2\pi}}\exp\left[\frac{-(v_i-\alpha)^2}{2\beta^2}\right]\right]\right\}\end{aligned} \tag{66}$$

In order to resolve Eq. (66) various methods can be used [221].

4.12. Maximum entropy probability density function (ME_M.pdf)

A probability density function $f(v)$ which is defined in the interval a,b and which is obtained by maximising Shannon's entropy [222] subject to the following restrictions (a) and (b), has the form given by Eq. (67) [223]. The restrictions are that: (a) the probability density function $f(v)$ must be such that the area below the curve, in the interval [a,b], is equal to one, (b) that the M low-order statistical moments with respect to the origin of the theoretical distribution must be equal to the M low-order statistical moments with respect to the origin, $m'_j(j=1,\ldots,M)$, determined numerically from the sample

$$f(v;\lambda_1,\ldots,\lambda_M)=\exp\left[\lambda_0+\sum_{i=1}^{M}\lambda_i v^i\right] \tag{67}$$

where the parameter λ_0 is related to the M remaining parameters of the distribution by the following equation:

$$\lambda_0=-\ln\left[\int_a^b \exp\left(\sum_{i=1}^{M}\lambda_i v^i\right)\mathrm{d}v\right] \tag{68}$$

The corresponding cumulative distribution function of the maximum entropy probability density function is given by the following equation:

$$F(v;\lambda_1,\ldots,\lambda_M)=\int_a^v \exp\left(\lambda_0+\sum_{j=1}^{M}\lambda_j v^j\right)\mathrm{d}v \tag{69}$$

4.12.1. Moment estimates of the parameters

Eq. (70) represents M simultaneous non-linear equations that represent the restriction (b) indicated in Section 4.12. Eq. (70) has to be resolved in order to determine, using information provided from the sample, the λ_1,λ_2,..., λ_M distribution parameters [154]. The system of Eq. (70) has no analytical solution except for M = 1, and therefore it has to be resolved numerically. The parameter λ_0, which will take the non-null probability of calms, will be determined from Eq. (68).

$$\begin{aligned}&\left[\int_a^b v^j\exp\left(\sum_{i=1}^{M}\lambda_i v^i\right)\mathrm{d}v\right]\left[\int_a^b \exp\left(\sum_{i=1}^{M}\lambda_i v^i\right)\mathrm{d}v\right]^{-1}\\&=m'_j,\quad j=1,\ldots,M\end{aligned} \tag{70}$$

In theory, the number of moments M that can be used is not limited, but if the sample size becomes too small, the estimates of the higher moments will tend to become meaningless. Siddall [223] has analysed the ability of the method to reproduce known distributions. According to Siddall [223], the indications are that quite good density functions can be generated for most shapes using four or five moments. Most authors [204,205] consider Eq. (67) defined in the interval $a=v_{\min}$ and $b=v_{\max}$, where $v_{\min}$ and $v_{\max}$ are the minimum and maximum speeds of the data sample. This entails supposing that the probability that there can be wind speeds outside this interval is null. In order to eliminate this restriction, we consider in this paper, as did Ramírez and Carta

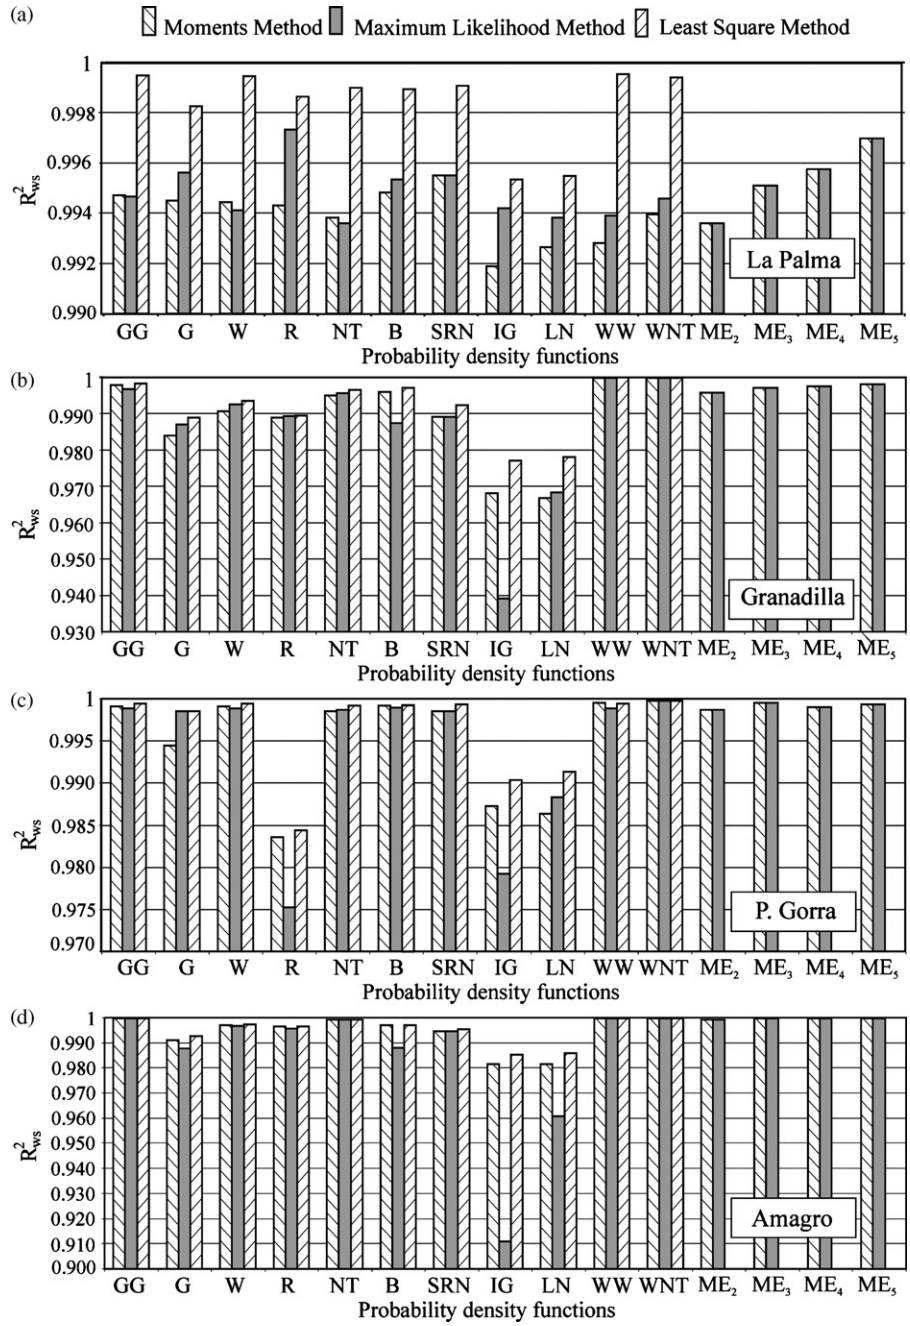

Fig. 1. Coefficients of determination R^2_{ws} obtained with the different non-hybrid PDFs analysed.

[154], that the margin of variation of the wind speed is in the interval $0 \leq v \leq \infty$.

5. Wind speeds used

In order to determine the maximum wind sourced energy potential that can be captured in the Canary Islands (Spain), a significant number of anemometer stations have been installed [206].

As a consequence of its geographical location,[20] the Canary Archipelago is regularly hit by trade winds from the north-east. However, the orographic and topographic characteristics of the islands and the effects of the sea breezes in certain areas give rise to the existence of different wind speed distributions in the same island.

In order to compare the different models included in the collection described in Section 3, four weather stations installed in the islands have been selected. The wind speeds recorded at these stations present different wind speed frequency histograms. These histograms, generated from the hourly mean wind speeds, can be considered to be representative of a significant number of weather stations.

Table 1 shows the number of stations, the geographical coordinates, the heights above ground level, the data recording period, the mean (m), variance (s^2), the relative frequency of calms (θ_0) (null wind speeds), maximum recorded wind speed ($v_{\max}$),

[20] The Canary Archipelago is located to the north-west of the African continent, between latitude 27°37′ and 29°25′ north (subtropical position) and longitude 13°20′ and 18°10′ west of Greenwich. The Canary Archipelago is approximately 1000 km from the Spanish mainland coast, and the closest and furthest distances from the African coast are 100 km and 500 km, respectively.

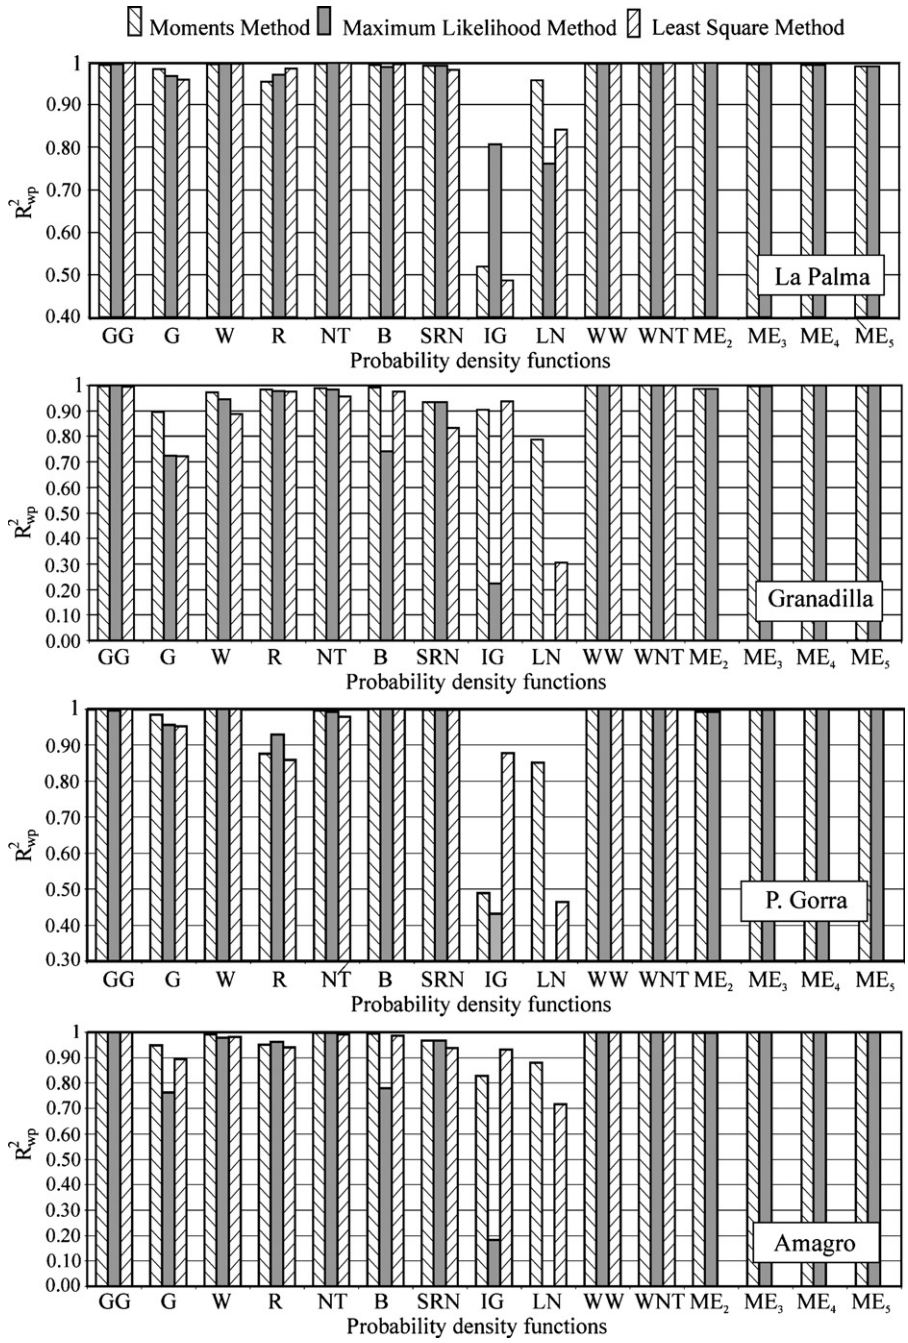

Fig. 2. Coefficients of determination R^2_{wp} obtained with the different non-hybrid PDFs analysed.

coefficient of skewness (Sk), coefficient of kurtosis (Kt) and median (Me). Figs. 3(a), 4(a), 5(a) and 6(a) show the wind speed frequency histograms.

6. Analysis of the results obtained

Tables 2–5 contain the values of the parameters of the different standard distribution laws analysed. Table 6 shows the values of the parameters of the laws generated by applying the principle of maximum entropy. Bearing in mind the work of Siddall [223], in this paper four types of ME_M.pdf[21] have been generated. These PDFs have been generated using 2, 3, 4 and 5 low-order statistical moments with respect to the origin determined numerically from the sample. The Mathcad Software 2001i programme of MathSoft Engineering & Education Inc. [224], was used to find the values of the parameters of the different PDFs analysed.[22]

Fig. 1(a) shows, for the case of La Palma, the values of the coefficients of determination R^2_{ws} obtained with the different PDFs

[21] *M* represents the number of moments used to generate the PDF.

[22] When you solve an equation, by default Mathcad uses an *AutoSelect* procedure to choose an appropriate solving algorithm. In the case of a non-linear system, *AutoSelect* uses the conjugate gradient solver; if that fails to converge, the Levenberg–Marquadt solver; if that too fails, the Quasi–Newton solver. These methods use different algorithms to determine the curvature and direction in which the search is to proceed. Although you can choose a specific method from the popup menu if necessary.

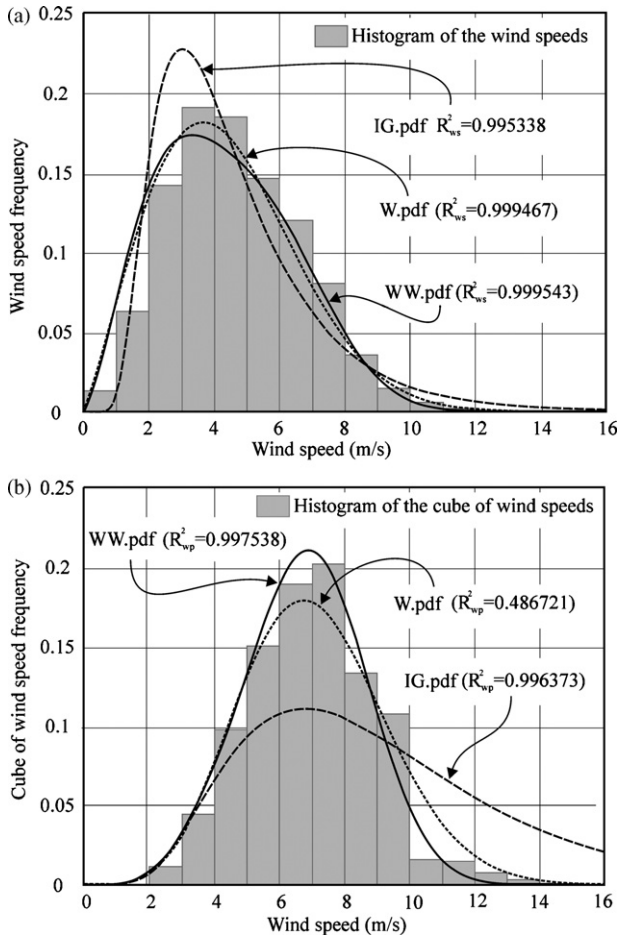

Fig. 3. (a) Relative frequency histogram of wind speed in La Palma on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}; (b) relative frequency histogram of the cube of the wind speed in La Palma on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}.

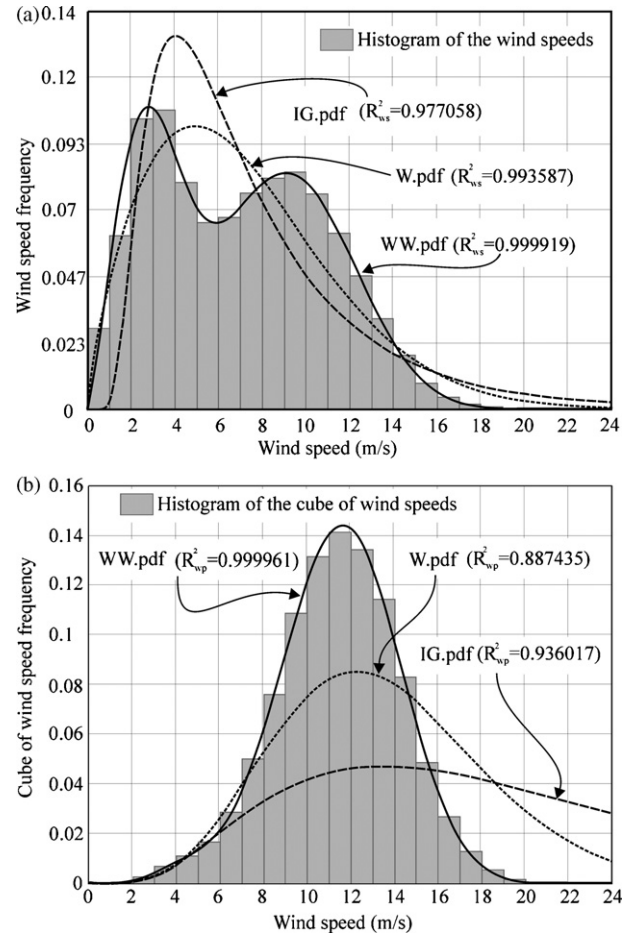

Fig. 4. (a) Relative frequency histogram of wind speed in Granadilla on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}; (b) relative frequency histogram of the cube of the wind speed in Granadilla on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}.

for wind speed.[23] This Fig. 1 also shows the values of R^2_{ws} obtained when the parameters of the PDFs have been estimated using the MM, MLM and LSM. Fig. 1(b)–(d) also represent these coefficients of determination, but in reference to the stations named Granadilla, P. Gorra and Amagro.

Fig. 2(a) shows, for La Palma, the values of R^2_{wp} obtained with the PDFs for wind power density [174,185,202]. Fig. 2(b)–(d) also represent these R^2_{wp}, but in reference to the stations named Granadilla, P. Gorra and Amagro.

It can be seen in Fig. 1 that, independently of the shape of the wind speed histogram and of the type of PDF, it is estimation through LSM which supplies the highest values of R^2_{ws}. However, as can be seen in Fig. 2, this is not always true in the case of wind power densities. In order to achieve high values of R^2_{wp} it is a necessary condition that the PDFs for wind speed have a good fit to the upper tails of the wind speed frequency histograms.[24] This fact can be seen in Figs. 3–6. Figs. 3(a)–6(a) show the wind speed histograms of the stations analysed. The W.pdf and the PDFs which have presented the highest and lowest values of R^2_{ws} have been superimposed on these histograms. Figs. 3(b)–6(c) show the frequency histograms of the cube of the wind speed and the PDFs for wind power density.

It should be pointed out that, with the exception of the PDFs that can be linearized (W.pdf and R.pdf), the estimation of the parameters with LSM requires the use of numerical techniques to resolve Eq. (1). These techniques require a starting point or base point.[25] Good starting values will often allow an iterative technique to converge to a solution much faster than would otherwise be possible. Moreover, inadequate starting values could give rise to Eq. (1) not converging to the optimum solution.[26]

As mentioned in Section 3.1, when the variables are random,[27] the MLM provides a consistent approach to parameter estimation problems and also has desirable mathematical and optimality properties. However, with the exception of certain PDFs that are easily resolved (R.pdf, NR.pdf, LN.pdf and IG.pdf), or which quickly

[23] According to Carta et al. [189], the R^2_{ws} obtained would have been lower if these had been estimated using the probability density functions instead of the cumulative distribution functions.

[24] This is due to the fact that high wind speeds provide much more power than low wind speeds. Then, certain differences between the PDFs for wind speed and the wind speed frequency histograms in the upper tails are transformed into considerable differences between the PDFs for wind power and frequency histograms of the cube of wind speed.

[25] All the iterative procedures require initial values of the parameters to be estimated.

[26] For example, the probability of success with the Newton–Raphson method [217] increases considerable when choosing acceptable initial values of the parameters.

[27] As pointed out in Section 3.3, the wind speed recorded at short intervals of time usually presents dependence.

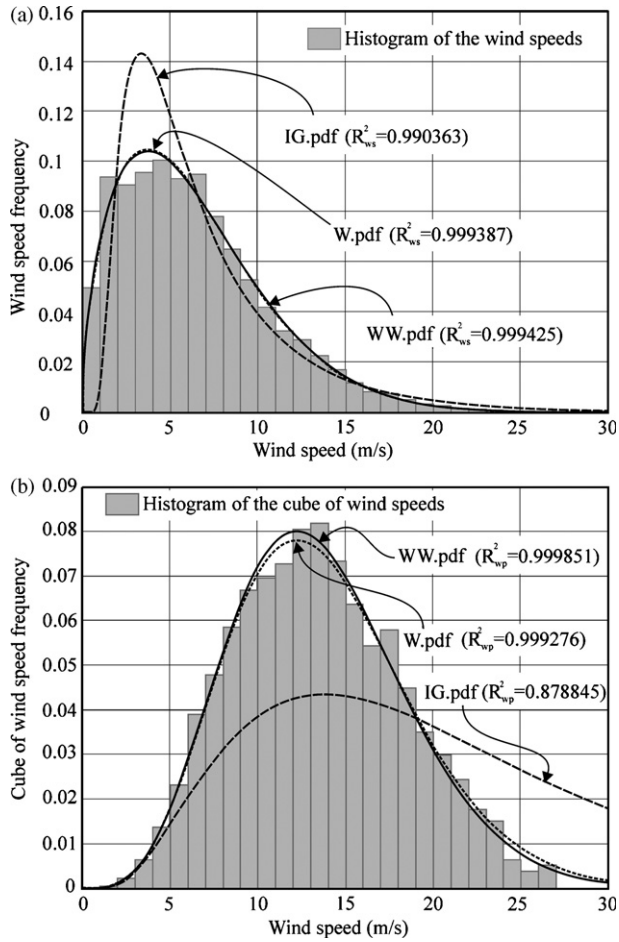

Fig. 5. (a) Relative frequency histogram of wind speed in P. Gorra on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}; (b) relative frequency histogram of the cube of the wind speed in P. Gorra on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}.

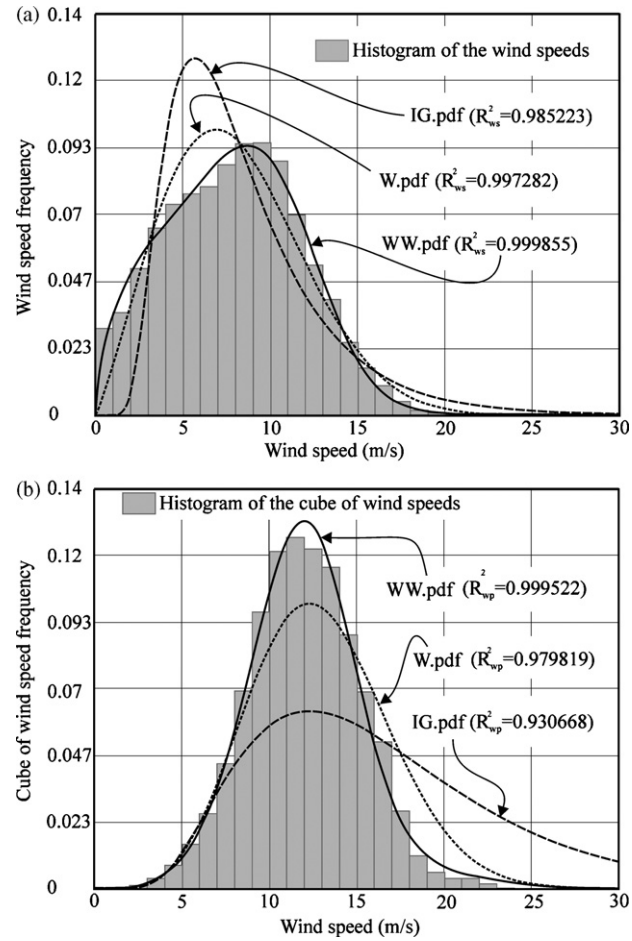

Fig. 6. (a) Relative frequency histogram of wind speed in Amagro on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}; (b) relative frequency histogram of the cube of the wind speed in Amagro on which have been superimposed the Weibull distribution and the distributions which have presented the highest and lowest values of R^2_{ws}.

converge to a solution (W.pdf, G.pdf), non-elementary numerical techniques may be required to estimate the parameters. In this sense, it should be pointed out that the numerical estimation of mixture models is not trivial and that MLM can be sensitive to the initial values of the parameters.

The MM, with the exception of the mixture distributions, the ME_M.pdf and the GG.pdf, do not present difficulties in the estimation of the parameters. Therefore, the parameters obtained using MM can constitute good starting points for estimation of the parameters via MLM or LSM. From the point of view of the values of R^2_{ws} obtained, no rule has been found which advices the use of MM as opposed to MLM or vice versa, in the case of non-random wind speeds.

From the different PDFs analysed the conclusion is reached that the mixture distributions are especially suitable for the representation of bimodal histograms, Fig. 4(a). However in all the unimodal cases considered, Figs. 3(a), 5(a) and 6(a), they have also provided the highest values of R^2_{ws}. The principal drawback, as already mentioned, is that they present greater complexity in the estimation of the parameters, whichever estimation method is used.

For most cases analysed, the IG.pdf and LN.pdf have presented the lowest values of R^2_{ws} and R^2_{wp} (Figs. 1 and 2), independently of the estimation method used. The R.pdf, due to the high rigidity of its shape, could not be fitted to all the wind speed frequency histograms (Figs. 1 and 2). In other words, it is unsuitable for representation of a wide range of wind regimes.

The GG.pdf, due to the fact it has two shape factors (α and η), presents higher flexibility than the W.pdf and, therefore, fits better a larger number of wind speed frequency histograms (Fig. 1). However, the GG.pdf presents the handicap of greater complexity in the estimation of the three parameters on which it depends.

The ME_M.pdf take into account the frequency of null winds [154]. In addition, when the MM has been used, the ME_M.pdf (with $M > 2$) has adapted better than most PDFs analysed to the wind speed frequency histograms and, fundamentally, to the frequency histograms of the cube of the wind speed (Fig. 2). Therefore, the ME_M.pdf (with $M > 2$) constitute a useful tool for evaluation of the available wind resources at a potential site.

Fig. 7 shows the values of $R^2_{ws,h}$ obtained through the use of hybrid PDFs compared to the values of R^2_{ws} obtained with standard PDFs. The dashed line at 45° has been drawn to observe the relation between both values of the coefficient of determination ($R^2_{ws,h} - R^2_{ws}$). Fig. 8 shows the values of $R^2_{wp,h}$ obtained through the use of hybrid PDFs compared to the values of R^2_{wp} obtained with standard PDFs.

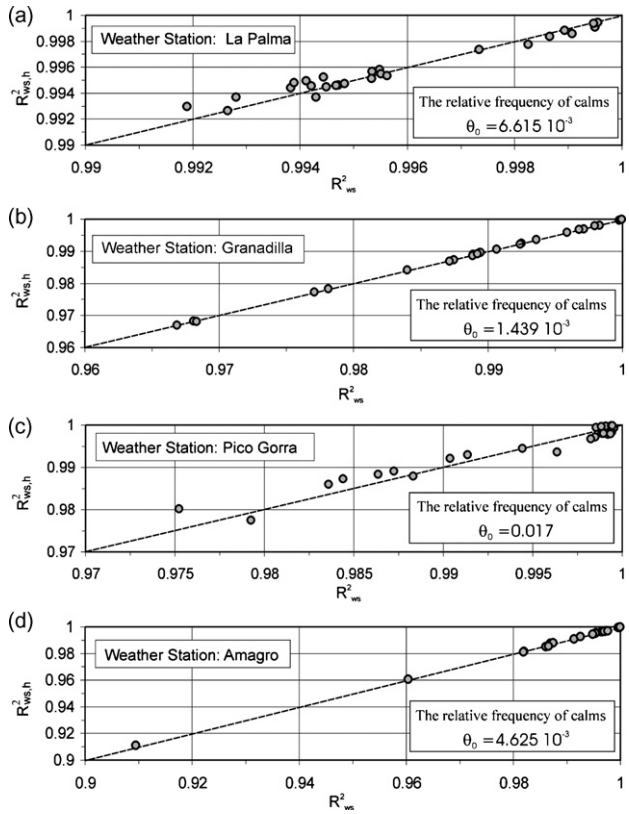

Fig. 7. Values of $R^2_{ws,h}$ obtained through the use of the hybrid distributions against the values of R^2_{ws} obtained through the use of non-hybrid distributions.

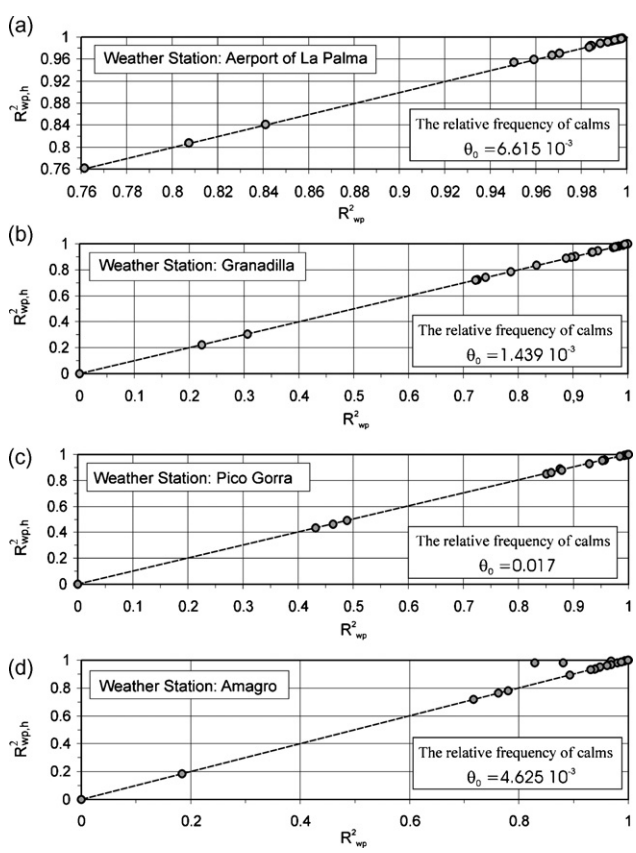

Fig. 8. Values of $R^2_{wp,h}$ obtained through the use of the hybrid distributions against the values of R^2_{wp} obtained through the use of non-hybrid distributions.

As can be seen in Fig. 7, for high values of R^2_{ws} no significant improvement in fit is observed,[28] for any of the stations analysed, when using hybrid PDFs. The stations in La Palma and Pico Gorra have the highest values of null wind speed frequencies (θ_0). At these stations, and for certain values of R^2_{ws}, a slight increase in fit is achieved when using hybrid PDFs. However, in Fig. 8 only a slight increase in fit is observed when using hybrid PDFs at Amagro station and for values of R^2_{wp} between 0.8 and 0.9. Therefore, with respect to the hybrid distributions analysed, and for the values found of θ_0 ($<$1.7%),[29] the same conclusions are drawn as made by Tuller and Bret [186].

7. Conclusions

In this paper we have seen a review of a variety of PDFs that have been proposed in the scientific literature related to renewable energies to describe wind speed frequency distributions. In addition, new hybrid PDFs have been proposed, such as that defined by Takle and Brown [190], from the standard PDFs that do not take into account the frequencies of null wind speeds.

Details have been given of the analytical and numerical procedures which are required for the estimation of parameters through MM, MLM and LSM. A comparison has also been made in terms of the degree of fit to experimental frequency histograms of wind speed and cube of the wind speed.

The conclusion is reached that the Weibull distribution of two parameters presents a series of advantages with respect to the PDFs analysed. Amongst other advantages, we can mention: (a) its flexibility; (b) the dependence on only two parameters; (c) the simplicity of the estimation of its parameters, independently of the method used; (d) the W.pdf can be expressed in closed form, which simplifies its use; (e) when its parameters are estimated from the sample, it has specific goodness of fit tests [151].

However, the W.pdf cannot represent all the wind regimes encountered in nature such as, for example, those with high percentages of null wind speeds, bimodal distributions, etc. Therefore, its generalised use cannot be justified, and a suitable PDF must be selected for each wind regime in order to minimise errors in the estimation of the energy produced by a WECS [189]. In this sense, the extensive collection of PDFs proposed in this paper constitutes a valuable catalogue.

The mixture distributions of two Weibull distributions or a Weibull distribution and a normal truncated distribution (MWNT.pdf) are particularly suitable for bimodal wind regimes, but they have also provided, for all the unimodal cases considered, the highest values of the coefficient of determination.

The lognormal and inverse Gaussian distributions have presented for all cases analysed the lowest values of R^2_{ws} and R^2_{wp}, independently of the estimation method used. These results contradict the conclusions obtained by other authors [187,199].

The R.pdf is not suitable for representation of a wide range of wind regimes.

The ME_M.pdf (with $M > 2$) constitutes a useful tool for evaluation of wind resources available at a potential site.

The LSM is the method which provides the highest values of R^2_{ws}. However, in order to achieve high values of R^2_{wp} a necessary condition is that the PDFs for wind speed have a good fit to the upper tails of the wind speed frequency histograms.

With the exception of the PDFs that can be linearized (Weibull and Rayleigh), estimation of the parameters through LSM requires

[28] The majority of the points are found over the straight line.

[29] Weather stations with very high values of null wind speeds have not been analysed, since values of θ_0 in the order of 0.49 or 0.52, such as those presented by Merzouk [191], imply winds that are poorly suitable for energy use through a WECS.

the use of numerical techniques and starting points or base points that may complicate the calculations. When the wind speeds are random, the MLM provides a consistent approach to parameter estimation problems and also has desirable mathematical and optimality properties. However, with the exception of certain PDFs which are easily resolved (Rayleigh, square-root normal, lognormal and inverse Gaussian), or which converge rapidly to a solution (Weibull and Gamma), they may require non-elementary numerical techniques for parameter estimation. The MM, with the exception of the mixture distributions, the ME_M.pdf and the GG.pdf, do not present difficulties in parameter estimation. Therefore, the parameters obtained using MM can constitute good starting points for parameter estimation with MLM or LSM and numerical techniques.

From the point of view of the values of R^2_{ws} obtained, no rule has been found that would advise the use of MM as opposed to MLM or vice versa, in the case of non-random wind speeds.

With respect to the hybrid distributions analysed and for the values found of θ_0 ($<1.7\%$), the same conclusions are drawn as made by Tuller and Bret [186]. Namely, there is no indication that hybrid distributions offer advantages over the standard distributions.

References

[1] Justus CG. Winds and wind system performance, 1st ed., US: Franklin Institute Press; 1978.
[2] Koeppl GW. Putnam's power from the wind, 2nd ed., New York: Van Nostrand Reinhold; 1982.
[3] Putnam PC. Power from the wind, 1st ed., New York: Van Nostrand Reinhold; 1948.
[4] Sherlock RH. Analyzing winds for frequency and duration. Meteorological Monographs 1951;1:42–9.
[5] Ossenbrugen PJ, Pregent GP, Meeker LD. Offshore wind power potential. Journal of The Energy Division 1979;105:81–92.
[6] Lavagnini A, Stellato G, Tosato GC. Climatological analysis of Italian data wind energy applications. In: Palz W, Schnell W, editors. Wind energy, vol. 2. Holland: D. Reider Publishing Company; 1983. p. 97–103.
[7] Kaminsky FC. Four probability densities (log-normal, gamma, Weibull, and Rayleigh) and their application to modelling average hourly wind speed. In: Proceedings of the international solar energy society, sections 14–25; 1977. 19.6–19.10.
[8] Chadee JC, Sharma C. Wind speed distributions: a new catalogue of defined models. Wind Engineering 2001;25:319–37.
[9] Roldan J, García A, Losada A. A stochastic model for wind ocurrence. Journal of Applied Meteorology 1982;21:740–4.
[10] Auwera LV, Meyer F, Malet LM. The use of the Weibull three-parameter model for estimating mean wind power densities. Journal of Applied Meteorology 1980;19:819–25.
[11] Tar K. Some statistical characteristics of monthly average wind speed at various heights. Renewable and Sustainable Energy Reviews 2007. doi:10.1016/j.rser.2007.01.014.
[12] Essenwanger OM. Applied statistics in atmospheric science, 1st ed., New York: Elsevier; 1976.
[13] Crutcher HL, Baer L. Computations from elliptical wind distribution statistics. Journal of Applied Meteorology 1962;14:1512–20.
[14] Smith OE. An application of distributions derived from the bivariate normal density function. In: Proceedings of the international symposium on probability and statistics in the atmospheric sciences; 1971. p. 162–8.
[15] McWilliams B, Newmann MM, Sprevak D. The probability distribution of wind velocity an direction. Wind Engineering 1979;3:269–73.
[16] McWilliams B, Sprevak D. The estimation of the parameters of the distribution of wind speed and direction. Wind Engineering 1980;4:227–38.
[17] Weber RO. Estimators for the standard deviation of horizontal wind direction. Journal of Applied Meteorology 1997;36:1407–15.
[18] Weber RO. Estimator for the standard deviation of wind direction based on moments of the Cartesian components. Journal of Applied Meteorology 1991;30:1341–52.
[19] Colin B, Coupal B, Frayce D. Considerations of the effects of winds on the drift of oil slicks at sea: statistical and temporal aspects of wind velocity, direction and persistence. Wind Engineering 1987;11:51–65.
[20] Carta JA, Ramírez P, Bueno C. A joint probability density function of wind speed and direction for wind energy analysis. Energy Conversion and Management 2008;49:1309–20.
[21] Winger WK. Estimating wind power feasibility. Power Engineering 1976;(August):58–61.
[22] Winger WK. Estimations of wind speed frequency distributions using only the monthly average and fastest mile data. Journal Applied Meteorology 1977;16:244–7.
[23] Carlin J, Haslett J. The probability distribution of wind power from a dispersed array of wind turbine generators. Journal of Applied Meteorology 1982;21:303–13.
[24] Mihelić-Bogdanić A, Budin R. Specific wind energy as a function of mean speed. Renewable Energy 1992;2:573–6.
[25] Kaminsky FC, Kirchhoff RH. Bivariate probability models for the description ofrojoaverage wind speed at two heights. Solar Energy 1988;40:49–56.
[26] Haslett J, Kelledy E. The assessment of actual wind power availability in Ireland. International Journal of Energy Research 1979;3:333–48.
[27] Feron P, Lysen EH. Effective output and availability of wind turbines for household loads. Wind Engineering 1981;5:194–206.
[28] Hennessey JP. A comparison of the Weibull and Rayleigh distributions for estimating wind power potential. Wind Engineering 1978;2:156–64.
[29] Baker RW, Hennessey JP. Estimating wind power potential. Power Engineering 1977;(March):56–7.
[30] Corotis RB, Sigl AB, Klein J. Probability models of wind velocity magnitude and persistence. Solar Energy 1978;20:483–93.
[31] Oliva RB. Result after first year of automated wind measurements in Santa Cruz, Southern Patagonia. Wind Engineering 1997;21:113–24.
[32] Jowder FAL. Weibull and Rayleigh distribution functions of wind speeds in Kingdom of Bahrain. Wind Engineering 2006;30:439–45.
[33] Celik AN. A statistical analysis of wind power density based on the Weibull and Rayleigh models at southern region of Turkey. Renewable Energy 2003;29:593–604.
[34] Ilinca A, McCarthy E, Chaumel JL, Rétiveau JL. Wind potencial assesment of Québec Province. Renewable Energy 2003;28:1881–97.
[35] Kose R, Arif MO, Erbas O, Tugcu A. The analysis of wind data and wind energy potential in Kutahya, Turkey. Renewable and Sustainable Energy Reviews 2004;8:277–88.
[36] Gökçek M, Bayülken A, Bekdemir Ş Investigation of wind characteristics and wind energy potential in Kirklareli, Turkey. Renewable Energy 2007;32:1739–52.
[37] Şahin AZ, Aksakal A. Wind power energy potential at the northeastern region of Saudi Arabia. Renewable Energy 1998;14:435–40.
[38] Algifri AH. Wind energy potential in Aden-Yemen. Renewable Energy 1998;13:255–60.
[39] Jamil M, Parsa S, Majidi M. Wind power statistics and an evaluation of wind energy density. Renewable Energy 1995;6:623–8.
[40] Faoui H, Bahraui J, Darwish AS, Sayigh AAM. Wind energy potential in Morocco. Renewable Energy 1991;1:1–8.
[41] Nasir SM, Raza SM, Jafri YZ. Wind energy estimation at Quetta. Renewable Energy 1991;1:263–7.
[42] Akpinar EK, Akpinar S. An assessment on seasonal analysis of wind energy characteristics and wind turbine characteristics. Energy Conversion and Management 2005;46:1848–67.
[43] Akpinar EK, Akpinar S. A statistical analysis of wind speed data used in installation of wind energy conversion systems. Energy Conversion and Management 2005;46:515–32.
[44] Essa KSM, Embaby M. Statistical evaluation of wind energy at Inshas, Egypt. Wind Engineering 2005;29:83–8.
[45] Essa KSM, Mubarak F. Survey and assessment of wind-speed and windpower in Egypt, including air density variation. Wind Engineering 2006;30:95–106.
[46] Ulgen K, Hepbasli A. Determination of Weibull parameters for wind energy analysis of İzmir, Turkey. International Journal of Energy Research 2002;26:495–506.
[47] Akpinar EK. A statistical investigation of wind energy potential. Energy Sources Part A Recovery Utilization and Environmental Effects 2006;28:807–20.
[48] Haslett J, Kelledy E. A note on the use of the models in the estimation of wind power availability. Wind Engineering 1981;5:6–11.
[49] Mathew S, Pandey KP, Kumar A. Analysis of wind regimes for energy estimation. Renewable Energy 2002;25:381–99.
[50] Celik AN. On the distributional parameters used in assessment of the suitability of wind speed probability density functions. Energy Conversion and Management 2004;45:1735–47.
[51] Balouktsis A, Chassapis D, Karapantsios TD. A nomogram method for estimating the energy produced by wind turbine generators. Solar Energy 2002;72:251–9.
[52] Pallabazzer R. Evaluation of wind-generator potentiality. Solar Energy 1995;55:49–59.
[53] Castellanos F, Ramesar VI. Characterization and estimation of wind energy resources using autoregressive modelling and probability density functions. Wind Engineering 2006;30:1–14.
[54] Jamil M. Wind power statistics and evaluation of wind energy density. Wind Engineering 1994;18:227–40.
[55] Mengelkamp HT. On the energy output estimation of wind turbines. International Journal of Energy Research 1988;12:113–23.
[56] Biswas S, Sraedhar BN, Singh YP. A simplified statistical technique for wind turbine energy output estimation. Wind Engineering 1995;19:147–55.
[57] Akpinar EK, Akpinar S. An assessment of wind turbine characteristics and wind energy characteristics for electricity production. Energy Sources Part A Recovery Utilization and Environmental Effects 2006;28:941–53.

[58] Ulgen K, Genc A, Hepbasli A, Oturanc G. Assessment of wind characteristics for energy generation. Energy Sources Part A Recovery Utilization and Environmental Effects 2004;26:1227–37.
[59] Şahin AZ, Aksakal A. A statistical analysis of wind energy potential at the eastern region of Saudi Arabia. International Journal of Energy Research 1999;23:909–17.
[60] Hiester TR, Pennell WT. The siting handbook for large wind energy systems, 1st ed., US: WindBooks; 1981.
[61] IEC 61400-12. Wind turbine generator systems—Part 12: Wind turbine power performance testing. 1st ed. International Electrotechnical Commission; 1998–2002.
[62] Davenport AG. The relationship of wind structure to wind loading. In: Proceedings of the conference on wind effects on structures; 1963. p. 19–82.
[63] Hennessey JP. Some aspects of wind power statistics. Journal Applied Meteorology 1977;16:119–28.
[64] Essenwanger OM. Applied statistics in atmospheric science. Part A: Frequencies and curve fitting, 1st ed., New York: Elsevier; 1976.
[65] Justus CG, Hargraves WR, Yalcin A. Nationwide assessment of potential output from wind powered generators. Journal of Applied Meteorology 1976;15:673–8.
[66] Stevens MJM, Smulders PT. The estimation of the parameters of the Weibull wind speed distribution for wind energy utilization purposes. Wind Engineering 1979;3:132–45.
[67] Justus CG, Hargraves WR, Mikhail A, Graber D. Methods for estimating wind speed frequency distributions. Journal of Applied Meteorology 1978;17:350–3.
[68] Doran JC, Verholek MG. A note on vertical extrapolation for Weibull velocity distribution parameters. Journal of Applied Meteorology 1978;17:410–2.
[69] Ngala GM, Alkali B, Aji MA. Viability of wind energy as a power generation source in Maiduguri, Borno state, Nigeria. Renewable Energy 2007;32:2242–6.
[70] Shata ASA, Hanitsch R. The potential of electricity generation on the east coast of Red Sea in Egypt. Renewable Energy 2006;31:1597–615.
[71] Shata ASA, Hanitsch R. Evaluation of wind energy potential and electricity generation on the coast of Mediterranean Sea in Egypt. Renewable Energy 2006;31:1183–202.
[72] Zhou W, Yang H, Fang Z. Wind power potential and characteristic analysis of the Pearl River Delta region, China. Renewable Energy 2006;31:739–53.
[73] Al-Nassar W, Alhajraf S, Al-Enizi A, Al-Awadhi L. Potential wind power generation in the State of Kuwait. Renewable Energy 2005;30:2149–61.
[74] Jaramillo OA, Saldaña R, Miranda U. Wind power potential of Baja California Sur, México. Renewable Energy 2004;29:2087–100.
[75] Vogiatzis N, Kotti K, Spanomitsios S, Stoukides M. Analysis of wind potential and characteristics in North Aegean, Greece. Renewable Energy 2004;29:1193–208.
[76] Weisser D. A wind energy analysis of Grenada: an estimation using the 'Weibull' density function. Renewable Energy 2003;28:1803–12.
[77] Bivona S, Burlon R, Leone C. Hourly wind speed analysis in Sicily. Renewable Energy 2003;28:1371–85.
[78] Ozerdem B, Turkeli M. An investigation of wind characteristics on the campus of Izmir Institute of Technology, Turkey. Renewable Energy 2003;28:1013–27.
[79] Chang TJ, Wu YT, Hsu HY, Chu CR, Liao CM. Assessment of wind characteristics and wind turbine characteristics in Taiwan. Renewable Energy 2003;28:851–71.
[80] Karsli VM, Geçit C. An investigation on wind power potential of Nurdağı-Gaziantep, Turkey. Renewable Energy 2003;28:823–30.
[81] Shabbaneh R, Hasan A. Wind energy potential in Palestine. Renewable Energy 1997;11:479–83.
[82] Mayhoub AB, Azzam A. A survey on the assessment of wind energy potential in Egypt. Renewable Energy 1997;11:235–47.
[83] Ramachandra TV, Subramanian DK, Joshi NV. Wind energy potential assessment in Uttara Kannada district of Karnataka, India. Renewable Energy 1997;10:585–611.
[84] Abdeladim K, Romeo R, Magrì S. Wind mapping of a region in the north-east of Algeria. Renewable Energy 1996;9:789–93.
[85] Scerri E, Farrugia R. Wind data evaluation in the Maltese Islands. Renewable Energy 1996;7:109–14.
[86] Sopian K, Othman MY, Wirsat HA. The wind energy potential of Malaysia. Renewable Energy 1995;6:1005–16.
[87] Tolun S, Menteş S, Aslan Z, Yükselen MA. The wind energy potential of Gökçeada in the Northern Aegean Sea. Renewable Energy 1995;6:679–85.
[88] Ranganathan CR, Ramanathan M, Swaminathan KR. Estimation of wind power availability in Tamil Nadu. Renewable Energy 1991;1:429–34.
[89] Khogali A, Albar OF, Yousif B. Wind and solar energy potential in Makkah (Saudi Arabia)-comparison with Red Sea coastal sites. Renewable Energy 1991;1:435–40.
[90] Chinnasamy TV, Haridasan TM. Wind energy potential at Palkalainagar. Renewable Energy 1991;1:815–21.
[91] Bagiorgas HS, Assimakopoulos MN, Theoharopoulos D, Matthopoulos D, Mihalakakou GK. Electricity generation using wind energy conversion systems in the area of Western Greece. Energy Conversion and Management 2007;48:1640–55.
[92] Akpinar EK, Akpinar S. Determination of the wind energy potential for Maden-Elazig, Turkey. Energy Conversion and Management 2004;45:2901–14.
[93] Feregh GM. Wind energy potential in Bahrain. Energy Conversion and Management 1993;34:499–506.
[94] Sinha CS, Kandpal TC. Performance prediction of multivane windmills in India. Energy Conversion and Management 1991;32:43–50.
[95] Hussain M, Alam S, Reza KA, Sarkar M. A study of the wind speed and wind energy availability in Bangladesh. Energy Conversion and Management 1986;26:321–7.
[96] Eskin N, Artar H, Tolun S. Wind energy potential of Gökçeada Island in Turkey. Renewable and Sustainable Energy Reviews 2008;12:839–51.
[97] Borhan Y. Mesoscale interactions on wind energy potential in the northern Aegean region: a case study. Renewable and Sustainable Energy Reviews 1998;2:353–60.
[98] Mulugetta Y, Drake F. Assessment of solar and wind energy resources in Ethiopia. II. Wind energy. Solar Energy 1996;57:323–34.
[99] Rehman S, Halawani TO, Husain T. Weibull parameters for wind speed distribution in Saudi Arabia. Solar Energy 1994;53:473–9.
[100] Katsoulis BD, Metaxas DA. The wind energy potential of western Greece. Solar Energy 1992;49:463–76.
[101] Poje D, Cividini B. Assessment of wind energy potential in Croatia. Solar Energy 1988;41:543–54.
[102] Exell RHB, Fook CT. The wind energy potential of Malaysia. Solar Energy 1986;36:281–9.
[103] Gupta BK. Weibull parameters for annual and monthly wind speed distributions for five locations in India. Solar Energy 1986;37:469–71.
[104] Exell RHB. The wind energy potential of Thailand. Solar Energy 1985;35:3–13.
[105] Sulaiman MY, Akaak AM, Wahab MA, Zakaria A, Sulaiman ZA, Suradi J. Wind characteristics of Oman. Energy 2002;27:35–46.
[106] Cellura M, Cirrincione G, Marvuglia A, Miraoui A. Wind speed spatial estimation for energy planning in Sicily: introduction and statistical analysis. Renewable Energy 2008;33:1237–50.
[107] Fagbenle RL, Karayiannis TG. On the wind energy resource of Nigeria. International Journal of Energy Research 1994;18:493–508.
[108] Koumanoudis N. Wind energy study of the Greek Islands. Wind Engineering 1988;12:250–6.
[109] Sahin B, Bilgili M, Akilli H. The wind power potential of the eastern Mediterranean region of Turkey. Journal of Wind Engineering and Industrial Aerodynamics 2005;93:171–83.
[110] Darwish ASK, Sayigh AAM. Wind energy potential in Iraq. Journal of Wind Engineering and Industrial Aerodynamics 1988;27:179–89.
[111] Coelingh JP, van Wijk AJM, Cleijne JW, Pleune R. Description of the North Sea wind climate for wind energy applications. Journal of Wind Engineering and Industrial Aerodynamics 1992;39:221–32.
[112] Coelingh JP, van Wijk AJM, Holtslag AAM. Analysis of wind speed observations over the North Sea. Journal of Wind Engineering and Industrial Aerodynamics 1996;61:51–69.
[113] Lu L, Yang H. Wind data analysis and case study of wind power generation in Hong Kong. Wind Engineering 2001;25:115–23.
[114] Palese C, Lässig JL, Cogliati MG, Bastansti MA. Wind regime and wind power in North Patagonia, Argentina. Wind Engineering 2000;25:361–77.
[115] Genc A, Erisoglu M, Pekgor A, Oturanc G, Hepbasli A, Ulgen K. Estimation of wind power potential using Weibull distribution. Energy Sources Part A Recovery Utilization and Environmental Effects 2005;27:809–22.
[116] Feretić D, Tomšić Ž, Čavlina N. Feasibility analysis of wind-energy utilization in Croatia. Energy 1999;24:239–46.
[117] Pavia EG, O'Brien JJ. Weibull statistics of wind speed over the ocean. Journal of Applied Meteorology 1986;25:1324–32.
[118] Dixon JC, Swift RH. Offshore wind power systems: a review of developments and comparison of national studies. Wind Engineering 1986;10:64–77.
[119] Chang TJ, Tu YL. Evaluation of monthly capacity factor of WECS using chronological and probabilistic wind speed data: a case study of Taiwan. Renewable Energy 2007;32:1999–2010.
[120] Hu S, Jung-ho Cheng J. Performance evaluation of pairing between sites and wind turbines. Renewable Energy 2007;32:1934–47.
[121] Pallabazzer R. Previsional estimation of the energy output of windgenerators. Renewable Energy 2004;29:413–20.
[122] Celik AN. Weibull representative compressed wind speed data for energy and performance calculations of wind energy systems. Energy Conversion and Management 2003;44:3057–72.
[123] Abed KA, El-Mallah AA. Capacity factor of wind turbines. Energy 1997;22:487–91.
[124] Celik AN. Energy output estimation for small-scale wind power generators using Weibull-representative wind data. Journal of Wind Engineering and Industrial Aerodynamics 2003;91:693–707.
[125] Jones CN. Notes on the effect of site wind-speed frequency distribution and machine performance characteristics on the annual energy output a WECS. Wind Engineering 1986;10:31–46.
[126] Jones CN. The prediction of wind turbine energy output; a brief survey. Wind Engineering 1988;12:76–87.
[127] Sasi KK, Basu S. On the prediction of capacity factor and selection of size of wind electric generators-a study based on Indian sites. Wind Engineering 1997;21:73–88.
[128] Weisser D, Foxon TJ. Implications of seasonal and diurnal variations of wind velocity for power output estimation of a turbine: a case study of Grenada. International Journal of Energy Research 2003;27:1165–79.

[129] Pallabazzer R. Parametric analysis of wind siting efficiency. Journal of Wind Engineering and Industrial Aerodynamics 2003;91:1329–52.
[130] Lackner MA, Elkinton CN. An analytical framework for offshore wind for layout optimization. Wind Engineering 2007;31:17–31.
[131] García-Bustamante E, González-Rouco JF, Jiménez PA, Navarro J, Montávez JP. The influence of the Weibull assumption in monthly wind energy estimation. Wind Energy 2008. doi: 10.1002/we.270.
[132] Celik AN. A simplified model for estimating yearly wind fraction in hybrid-wind energy systems. Renewable Energy 2006;31:105–18.
[133] Celik AN. A simplified model for estimating the monthly performance of autonomous wind energy systems with battery storage. Renewable Energy 2003;28:561–72.
[134] Celik AN. The system performance of autonomous photovoltaic-wind hybrid energy systems using synthetically generated weather data. Renewable Energy 2002;27:107–21.
[135] Carathers RG, Bragg GM. Statistical aspects of wind pumping in the Sahelian regions of Niger. Wind Engineering 1986;10:196–208.
[136] Feron P. The use of windpower in autonomous reverse osmosis seawater desalination. Wind Engineering 1985;9:180–99.
[137] Daniel AR, Chen AA. Stochastic simulation and forecasting of hourly average wind speed sequences in Jamaica. Solar Energy 1991;46:1–11.
[138] Dixon JC, Swift RH. The dependence of wind speed and Weibull characteristics on height for offshore winds. Wind Engineering 1984;8:87–98.
[139] Sedefian L. On the vertical extrapolation of mean wind power density. Journal of Applied Meteorology 1980;19:488–93.
[140] Uitzinger J, Verkuijlen E, van Mierlo B. On the impracticability of Weibull statistics in the comparison of wind speed time series. Wind Engineering 1989;13:207–12.
[141] Aksoy HZ, Toprak ZF, Aytek A, Ünal NE. Stochastic generation of hourly mean wind speed data. Renewable Energy 2004;29:211131.
[142] Shamshad A, Bawadi MA, Hussin WMAW, Majid TA, Sanusi SAM. First and second order Markov chain models for synthetic generation of wind speed time series. Energy 2005;30:693–708.
[143] Alpay S, Bilir L, Ozdemir S, Ozerdem B. Wind speed time series characterization by Hilbert transform. International Journal of Energy Research 2006;30:359–64.
[144] Balouktsis A, Tsanakas D, Vachtsevanos G. Stochastic simulation of hourly and daily average wind speed sequences. Wind Engineering 1986;10:1–11.
[145] Nfaoui H, Buret J, Sayigh AAM. Stochastic simulation of hourly average wind speed sequences in Tangiers (Marocco). Solar Energy 1996;56:301–14.
[146] Chou KC, Corotis RB. Simulation of hourly wind speed and array wind power. Solar Energy 1981;26:199–212.
[147] Ettoumi FY, Sauvageot H, Adane AEH. Statistical bivariate modelling of wind using first-order Markov chain and Weibull distribution. Renewable Energy 2003;28:1787–802.
[148] Andrawus JA, Watson J, Kishk M. Wind turbine maintenance optimisation principles of quantitative maintenance optimisation. Wind Engineering 2007;31:101–10.
[149] Celik AN. Assessing the suitability of wind speed probability distribution functions based on wind power density. Renewable Energy 2003;28:1563–74.
[150] Lun IYF, Lam JC. A study of Weibull parameters using long-term wind observations. Renewable Energy 2000;20:5–153.
[151] Ramírez P, Carta JA. Influence of the data sampling interval in the estimation of the parameters of the Weibull wind speed probability density distribution: a case study. Energy Conversion and Management 2005;46:2419–38.
[152] Torres JL, García A, Prieto E, de Francisco A. Characterization of wind speed data according to wind direction. Solar Energy 1999;66:57–64.
[153] Garcia A, Torres JL, Prieto E, de Francisco A. Fitting wind speed distributions: a case study. Solar Energy 1998;62:139–44.
[154] Ramírez P, Carta JA. The use of wind probability distributions derived from the maximum entropy principle in the analysis of wind energy: a case study. Energy Conversion and Management 2006;47:2564–77.
[155] Carta JA, Ramírez P. Use of finite mixture distribution models in the analysis of wind energy in the Canarian Archipelago. Energy Conversion and Management 2007;48:281–91.
[156] Touré S. Investigations on the Eigen-coordinates method for the 2-parameter weibull distribution of wind speed. Renewable Energy 2005;30:511–21.
[157] Dorvlo ASS. Estimating wind speed distribution. Energy Conversion and Management 2002;43:2311–8.
[158] Seguro JV, Lambert TW. Modern estimation of the parameters of the Weibull wind speed distribution for wind energy analysis. Journal of Wind Engineering and Industrial Aerodynamics 2000;85:75–84.
[159] Cook JNJ. Discussion on modern estimation of the parameters of the Weibull wind speed distribution for wind speed energy analysis by Seguro JV, Lambert TW. Journal of Wind Engineering and Industrial Aerodynamics 2001;89:867–9.
[160] Pang WK, Foster JJ, Troutt MD. Estimation of wind speed distribution using Markov Chain Monte Carlo techniques. Journal of Applied Meteorology 2001;40:1476–84.
[161] Basumatary H, Sreevalsan E, Sasi KK. Weibull parameter estimation-a comparison of different methods. Wind Engineering 2005;29:309–16.
[162] Conradsen K, Nielsen LB, Prahm LP. Review of Weibull statistics for estimation of wind speed distributions. Journal of Climate and Applied Meteorology 1984;23:1173–83.
[163] Christofferson RD, Gillette DA. A simple estimator of the two-parameter Weibull distribution. Journal of Climate and Applied Meteorology 1987;26:323–5.
[164] Bowden GJ, Barker PR, Shestopal VO, Twidell JW. The Weibull distribution function and wind power statistics. Wind Engineering 1983;7:85–98.
[165] van Alphen K, van Sark WGJHM, Hekkert MP. Renewable energy technologies in the Maldives-determining the potential. Renewable and Sustainable Energy Reviews 2007;11:1650–74.
[166] Rehman S, El-Amin IM, Ahmad F, Shaahid SM, Al-Shehri AM, Bakhashwain JM, et al. Feasibility study of hybrid retrofits to an isolated off-grid diesel power plant. Renewable and Sustainable Energy Reviews 2007;11:635–53.
[167] Rehman S, El-Amin IM, Ahmad F, Shaahid SM, Al-Shehri AM, Bakhashwain JM. Wind power resource assessment for Rafha, Saudi Arabia. Renewable and Sustainable Energy Reviews 2007;11:937–50.
[168] Sahin B, Bilgili M, Akilli H. The wind power potential of the eastern editerranean region of Turkey. Journal of Wind Engineering and Industrial Aerodynamics 2005;93:171–83.
[169] Bechrakis DA, Deane JP, McKeogh EJ. Wind resource assessment of an area using short term data correlated to a long term data set. Solar Energy 2004;76:725–32.
[170] Karlis AD, Dermentzoglou JC, Papadopoulos DP. Wind energy surveying and technoeconomic assessment of identifiable WEC system installations. Energy Conversion and Management 2001;42:49–67.
[171] Pashardes S, Christofides C. Statistical analysis of wind speed and direction in Cyprus. Solar Energy 1995;55:405–14.
[172] Hunter R, Elliot G. Wind-diesel systems: a guide to the technology and its implementation, 1st ed., New York: Cambridge University Press; 1994.
[173] Manwell JF, McGowan JG, Rogers AL. Wind energy explained, 1st ed., Chichester: John Wiley & Sons Ltd.; 2002.
[174] Spera D. Wind turbine technology, 3rd ed., New York: ASME Press; 1995.
[175] Burton T, Sharpe D, Jenkins N, Bossanyi E. Wind energy handbook, 1st ed., Chichester: John Wiley & Sons Ltd; 2001.
[176] Gasch R, Twele J. Wind power plants, 1st ed., Berlin: Solarpraxis; 2002.
[177] Mathew S. Wind energy. Fundamentals, resource analysis and economics, 1st ed., New York: Springer; 2006.
[178] Lysen EH. Introduction to wind energy, 1st ed., The Netherlands: Consultancy Services Wind Energy Developing Countries; 1983.
[179] Freris LL. Wind energy conversion systems, 1st ed., UK: Prentice Hall; 1990.
[180] Harrison R, Hau E, Snel H. Large wind turbines: design and economics, 1st ed., New York: Wiley; 2000.
[181] Pastel MR. Wind and solar power systems, 1st ed., USA: CRC; 1999.
[182] Bianchi FD, De Battista H, Mantz RJ. Wind turbine control systems: principles, modelling and gain scheduling design, 1st ed., London: Springer-Verlag; 2007.
[183] Eggleston DM, Stoddard FS. Wind turbine engineering design, 1st ed., New York: Van Nostrand Reinhold; 1987.
[184] Twidell J, Weir T. Renewable energy resources, 6th ed., London: Spon Press; 2000.
[185] Hau E. Wind turbines. Fundamentals, technologies, application, economics, 1st ed., Germany: Springer; 2000.
[186] Tuller SE, Brett AC. The characteristics of wind velocity that favour the fitting of a Weibull distribution in wind speed analysis. Journal of Climate and Applied Meteorology 1984;23:124–34.
[187] Luna RE, Church HW. Estimation of long-term concentrations using a "Universal" wind speed distribution. Journal of Applied Meteorology 1974;13:910–6.
[188] Bogardi I, Matyasovzky I. Estimating daily wind speed under climate change. Solar Energy 1996;57:239–48.
[189] Carta JA, P. Ramírez S. Velázquez. Influence of the level of fit of a density probability function to wind-speed data on the WECS mean power output estimation. Energy Conversion and Management, doi:10.1016/j.enconman.2008.04.012.
[190] Takle ES, Brown J. Note on the use of Weibull to characterize wind speed data. Journal of Applied Meteorology 1978;17:556–9.
[191] Merzouk NK. Wind energy potential of Algeria. Renewable Energy 2000;21:553–62.
[192] Persaud S, Flynn D, Fox B. Potential for wind generation on the Guyana coastlands. Renewable Energy 1999;18:175–89.
[193] Nfaoui H, Buret J, Sayigh AAM. Wind characteristics and wind energy potential in Morocco. Solar Energy 1998;63:51–60.
[194] Katsoulis BD, Metaxas DA. The wind energy potential of Western Greece. Solar Energy 1992;49:463–76.
[195] Martner BE, Marwitz JD. Wind characteristics in Southern Wyoming. Journal of Applied Meteorology 1982;21:1815–27.
[196] Castino F, Rusca L, Solari G. Wind climate micro-zoning: a pilot application to Liguria Region (North Western Italy). Journal of Wind Engineering and Industrial Aerodynamics 2003;91:1353–75.
[197] Stewart DA, Essenwanger OM. Frequency distribution of wind speed near the surface. Journal of Applied Meteorology 1978;17:1633–42.
[198] Johnson NL, Kotz S, Balakishman N. 2nd ed., Continuous univariate distributions, vol. 1, 2nd ed. New York: John Wiley & Sons; 1994.
[199] Bardsley WE. Note on the use of inverse Gaussian distribution for wind energy applications. Journal of Applied Meteorology 1980;19:1126–30.

[200] Jaramillo OA, Borja MA. Wind speed análisis in La Ventosa, Mexico: a bimodal probability distribution case. Renewable Energy 2004;29:1613–30.
[201] Carta JA, Ramírez P. Analysis of two-component mixture Weibull statistics for estimation of wind speed distributions. Renewable Energy 2007;32:518–31.
[202] Carta JA, Mentado D. A continuous bivariate model for wind power density and wind turbine energy output estimations. Energy Conversion and Management 2007;48:420–32.
[203] Jaramillo OA, Borja MA. Bimodal versus Weibull wind speed distributions: an analysis of wind energy potential in La Venta, Mexico. Wind Engineering 2004;28:225–34.
[204] Akpinar S, Akpinar EK. Wind energy analysis based on maximum entropy principle (MEP)-type distribution function. Energy Conversion and Management 2007;48:1140–9.
[205] Shamilov A, Kantar YM, Usta I. Use of MinMaxEnt distributions defined on basis of MaxEnt method in wind power study. Energy Conversion and Management 2008;49:660–77.
[206] Calero R, Carta JA. Action plan for wind energy development in the Canary Islands. Energy Policy 2004;32:1185–97.
[207] Canavos G. Applied probability statistical methods, 1st ed., New York: Little Brown & Company; 1998.
[208] Draper NR, Smith H. Applied regression analysis, 1st ed., New York: John Wiley & Sons Inc.; 1998.
[209] Mage DT. Comments on "Frequency distribution of wind speed near the surface". Journal of Applied Meteorology 1970;18:1089–91.
[210] Corotis RB, Sigl AB, Cohen P. Variance analysis of wind characteristics for energy conversion. Journal of Applied Meteorology 1977;16:1149–57.
[211] Brown BG, Katz RW, Murphy AH. Time series models to simulate and forecast wind speed and wind power. Journal of Applied Meteorology 1984;23:1184–95.
[212] Haslett J, Raftery AE. Space–time modelling with long-memory dependence: assessing Ireland_s wind power resource. Applied Statistics 1989;38:1–50.
[213] Corotis RB. Statistical analysis of continuous data records. Transportation Engineering Journal 1974;100:195–206.
[214] Brett AC, Tuller SE. The autocorrelation of hourly wind speed observations. Journal of Applied Meteorology 1991;30:823–33.
[215] Zhang S, Jin J. Computation of special functions, 1st ed., New York: Wiley; 1996. p. 444.
[216] Stacy EW, Mihram GA. Parameter estimation for a generalizad gamma distribution. Technometrics 1965;7:349–58.
[217] Press WH, Teukolsky SA, Vetterling WT, Flannery BP. Numerical Recipes in fontran 77, 2nd ed., USA: Cambridge University Press; 1996.
[218] Wingo DR. Computing maximum likelihood parameter estimates of the Generalized Gamma distribution by numerical root isolation. IEEE Transactions on Reliability 1987;36:586–90.
[219] Bury K. Statistical distributions in engineering, 1st ed., UK: Cambridge University Press; 1999.
[220] Cohen AC. On estimation the mean and variance of singly truncated normal frequency distributions from the first three samples moments. Annals of the Institute of Statistical Mathematics 1950;3:37–44.
[221] Titterington DM, Smith AFM, Makov UE. Statistical analysis of finite mixture distributions, 2nd ed., New York: John Wiley and Sons Inc.; 1995.
[222] Shannon CE. A mathematical theory of communication. Bell System Technical Journal 1948;27:379–423.
[223] Siddall JN. Probabilistic engineering design, 1st ed., New York and Basel: Marcel Dekker Inc.; 1983.
[224] Kiryanov D. The Mathcad 2001i handbook, 1st ed., USA: Delmar 492 Thomson Learning; 2002.

Author's personal copy

Energy Conversion and Management 52 (2011) 1137–1149

Contents lists available at ScienceDirect

Energy Conversion and Management

journal homepage: www.elsevier.com/locate/enconman

Use of Bayesian networks classifiers for long-term mean wind turbine energy output estimation at a potential wind energy conversion site

José A. Carta [a,*], Sergio Velázquez [b], J.M. Matías [c]

[a] Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain
[b] Department of Electronics and Automatics Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain
[c] Department of Statistics, University of Vigo, Lagoas Marcosende, 36200 Vigo, Spain

ARTICLE INFO

Article history:
Received 20 January 2010
Accepted 4 September 2010

Keywords:
Bayesian network
Method of bins
Wind speed
Short-term records
Long-term records
Measure–correlate–predict

ABSTRACT

Due to the interannual variability of wind speed a feasibility analysis for the installation of a Wind Energy Conversion System at a particular site requires estimation of the long-term mean wind turbine energy output. A method is proposed in this paper which, based on probabilistic Bayesian networks (BNs), enables estimation of the long-term mean wind speed histogram for a site where few measurements of the wind resource are available. For this purpose, the proposed method allows the use of multiple reference stations with a long history of wind speed and wind direction measurements. That is to say, the model that is proposed in this paper is able to involve and make use of regional information about the wind resource. With the estimated long-term wind speed histogram and the power curve of a wind turbine it is possible to use the method of bins to determine the long-term mean energy output for that wind turbine. The intelligent system employed, the knowledgebase of which is a joint probability function of all the model variables, uses efficient calculation techniques for conditional probabilities to perform the reasoning. This enables automatic model learning and inference to be performed efficiently based on the available evidence. The proposed model is applied in this paper to wind speeds and wind directions recorded at four weather stations located in the Canary Islands (Spain). Ten years of mean hourly wind speed and direction data are available for these stations. One of the conclusions reached is that the BN with three reference stations gave fewer errors between the real and estimated long-term mean wind turbine energy output than when using two measure–correlate–predict algorithms which were evaluated and which use a linear regression between the candidate station and one reference station.

© 2010 Elsevier Ltd. All rights reserved.

1. Introduction

As stated by Hiester and Pennell [1], the interannual variability of wind speed at a potential wind energy conversion site is a very important issue. The energy that can be obtained with a wind turbine and, therefore, the economic feasibility of the project, will be very sensitive to the wind speed acting on the wind turbine over the working life of the facility.

On occasions no historical series of wind data measurements for a potential candidate site are available that would enable an assessment of the economic feasibility of the investment planned for the installation of a Wind Energy Conversion System (WECS). One option that can be employed to make up for the drawback of a lack of such data is to undertake a wind data measurement campaign over a sufficiently long period of time. According to Hiester and Pennell [1], it is difficult to accurately estimate the mean values of the behaviour of the wind at a potential candidate site with less than 10 years worth of data. This option therefore entails an increase in costs to cover the measurement campaign and, importantly, postponing the decision-taking process for a normally unacceptably length of time.

Another option entails the estimation by statistical methods of the interannual mean wind behaviour at the candidate site. Such methods rely on the existence of reference climatological stations installed at nearby sites, for which long-term wind resource measurements are available. These methods also require a wind data measurement campaign to be undertaken at the candidate site for a relatively short period of time (normally 1 year). Additionally, a portion of the reference station's wind data has to coincide in terms of length of time and dates with the measurement period of the candidate site.

For several authors [2–9], the first concern about a site under consideration for a wind power station is with the long-term (many years) mean wind speed. With this in mind, various methods have been proposed to estimate the long-term mean wind speed. Putnam [2] used a procedure that estimated the long-term mean wind speed $\overline{V}_c^{LT}$ at a candidate site that was based on knowledge of the

* Corresponding author. Tel.: +34 928 45 14 83; fax: +34 928 45 14 84.
E-mail address: jcarta@dim.ulpgc.es (J.A. Carta).

0196-8904/$ - see front matter © 2010 Elsevier Ltd. All rights reserved.
doi:10.1016/j.enconman.2010.09.008

Author's personal copy

mean wind speed determined over a short-term period $\overline{V}_c^{ST}$. This method is known as the method of ratios [3–5] and is given by Eq. (1)

$$\overline{V}_c^{LT} = \overline{V}_c^{ST}\left[\overline{V}_r^{LT}/\overline{V}_r^{ST}\right] \tag{1}$$

$\overline{V}_r^{LT}$ is the long-term mean for the reference site and $\overline{V}_r^{ST}$ is the short-term mean for the reference site (for the period coinciding with that of $\overline{V}_c^{ST}$.

Conrad and Pollak [5] listed the requirements that need to be met so that the method of ratios can be applied. The main requirement is equivalent, from a mathematical point of view, to the demand for a high spatial correlation between the candidate and reference site wind speeds. Corotis [1,3,4,6,7], using as a basis the hypothesis that the mean wind speeds at the candidate and reference site are distributed in accordance with a normal law, proposes a method that explicitly includes the spatial correlation coefficient (ρ^{LT}) between both sites and the standard deviations for the candidate site σ_c^{LT} and for the reference site σ_r^{LT}, Eq. (2)

$$\overline{V}_c^{LT} = \overline{V}_c^{ST} + \rho^{LT}\left[\overline{V}_r^{LT} - \overline{V}_r^{ST}\right]\left[\sigma_c^{LT}/\sigma_r^{LT}\right] \tag{2}$$

The values of ρ^{LT}, σ_c^{LT} are unknown and have to be estimated. Working on the hypothesis that the correlation varies little over time, the short-term rather than long-term correlation is normally used. Daniels and Schroeder [6] used a series of hypotheses to estimate σ_c^{LT}.

Other methods have been proposed in the scientific literature to tackle the problem arising from a site with few measurements of the wind resource [10–13]. However, the statistical method that has been most widely used over the last 20 years has been the measure–correlate–predict method (MCP) [14–18]. There are several variants of the method, but they are all based on the existence of statistical relationships between two time-series data sets and try to model the relationship between wind data (speed and direction) measured at the candidate site over a short period of time (normally 1 year) and wind data simultaneously measured at a reference site. By introducing into the model the long-term wind data (normally from several years) measured at the reference site, the long-term wind data series are estimated for the candidate site.

In the last few decades, the 'data mining' has become an increasingly common term [19] used to refer to the automatic or semi-automatic (assisted) process of extracting useful and understandable knowledge from a dataset [20]. Data mining incorporates numerous data analysis and model extraction techniques. This paper proposes the use of one of these techniques, probabilistic Bayesian networks (BNs) [19,21–23], to estimate the long-term mean wind speed frequency distribution (called a histogram) for a site with few measurements of the wind resource. The method proposed enables the use of multiple reference stations with a long history of wind speed and direction measurements. That is, the proposed model is able to make use of and involve regional information of the wind resource. The model has been implemented in Weka (Waikato Environment for Knowledge Analysis), free software available under the GNU General Public License [19] and developed by Waikato University (New Zealand). The intelligent system employed, the knowledgebase of which is a joint probability function of all the model variables, uses efficient calculation techniques for conditional probabilities to perform the reasoning. This enables automatic model learning and inference to be performed efficiently based on the available evidence. With the estimated long-term wind speed histogram and the power curve of a wind turbine it is possible to use the method of bins [24] or a probably density function that is fitted to the histogram [25–27] to determine the long-term mean energy output for that wind turbine. The proposed model is applied in this paper to wind speeds and wind directions recorded at four weather stations located on the Canary Islands (Spain). Ten years of mean hourly wind speed and direction data are available for these stations. To estimate the goodness-of-fit of the proposed estimation models a comparison has been made between the errors generated with these models and those generated with two measure–correlate–predict (MCP) algorithms which have been evaluated [13,14]: a linear regression method and a vector regression method.

For this purpose different metrics have been used. These metrics characterise the estimation of (1) the correct cumulative relative frequency histogram of the wind speed, (2) the correct mean wind power density and (3) the correct mean annual energy production. For this final analysis we have also used two commercial wind turbines of 330 and 800 kW rated power [28].

2. MCP methods used for comparison

The methods of Derrick [14] and Niesel et al. [13] have been chosen to compare their results with the alternative method based on BN as proposed by the authors.

2.1. Derrick method

Derrick [14] uses a linear regression to characterise the long-term (LT) relationship between the wind speeds of the candidate site (c) and of the reference site (r), Eq. (3). This method will be referred to in this paper as the linear regression method (LR).

$$(v_j)_c^{LT} = a(v_j)_r^{LT} + b \tag{3}$$

$(v_j)_c^{LT}$ are the estimated wind speeds at the candidate site, $(v_j)_r^{LT}$ are the measured wind speeds at the reference site, a and b are the slope and ordinate at the offset obtained from the linear regression [29], Eq. (4).

$$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^{n}(v_i^2)_r^{ST} & \sum_{i=1}^{n}(v_i)_r^{ST} \\ \sum_{i=1}^{n}(v_i)_r^{ST} & n \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n}(v_i)_c^{ST}(v_i)_r^{ST} \\ \sum_{i=1}^{n}(v_i)_c^{ST} \end{bmatrix} \tag{4}$$

In Eq. (4), $(v_i)_r^{ST}$ and $(v_i)_c^{ST}$ are the short-term (ST) mean hourly wind speeds at the reference site and the candidate site, respectively. n is the number of wind speed data.

Generally, the MCP method 'bins' or groups together the hourly wind speeds in terms of the wind direction at the reference site. For this purpose the data are divided into a specific number of wind direction sectors (normally 8 sectors of 45° or 12 of 30°). Then, the parameters a and b of the model are estimated, Eq. (4), for each wind direction sector. That is, a and b depend on the wind speed and wind direction. Thus, n in Eq. (4) is the number of wind speeds in the wind direction sector of the reference site that is being analysed.

The Mathcad Software 2001i of MathSoft Engineering & Education, Inc. [30] was used for the programming of this method.

2.2. Niesel et al. method

Niesel et al. [13] propose decomposing the wind speeds of the reference site and candidate site using two Cartesian axes (x, y) [31] and performing a two-dimensional linear regression, Eq. (5). In this paper, this method is referred to as the vector regression method (VR).

$$\begin{bmatrix} \{(v_x)_i\}_c^{LT} \\ \{(v_y)_i\}_c^{LT} \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} \{(v_x)_i\}_r^{LT} \\ \{(v_y)_i\}_r^{LT} \end{bmatrix} \tag{5}$$

Author's personal copy

The coefficients a_{ij} and b_j are determined by using a linear regression, on a separate basis for the different wind speed direction sectors that are under consideration. That is, the coefficients are estimated for each sector by means of the matrix product as indicated in Eq. (6)

$$\begin{bmatrix} b_1 & b_2 \\ a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} n & \sum_{i=1}^{n}\{(v_x)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_y)_i\}_r^{ST} \\ \sum_{i=1}^{n}\{(v_x)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_r^{ST})_x\}_i^2 & \sum_{i=1}^{n}\{(v_y)_i\}_r^{ST}\{(v_x)_i\}_r^{ST} \\ \sum_{i=1}^{n}\{(v_y)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_y)_i\}_r^{ST}\{(v_x)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_y)_i^2\}_r^{ST} \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n}\{(v_x)_i\}_c^{ST} & \sum_{i=1}^{n}\{(v_y)_i\}_c^{ST} \\ \sum_{i=1}^{n}\{(v_x)_i\}_c^{ST}\{(v_x)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_y)_i\}_c^{ST}\{(v_x)_i\}_r^{ST} \\ \sum_{i=1}^{n}\{(v_x)_i\}_c^{ST}\{(v_y)_i\}_r^{ST} & \sum_{i=1}^{n}\{(v_y)_i\}_c^{ST}\{(v_y)_i\}_r^{ST} \end{bmatrix}$$

The modules of each of the estimated long-term wind speeds for the candidate station are determined through Eq. (7)

$$(v_i)_c^{LT} = \left[\left\{(v_x)_i^2\right\}_c^{LT} + \left\{(v_y)_i^2\right\}_c^{LT}\right] \tag{7}$$

The long-term wind directions can be obtained from the components on the x- and y-axes of the estimated long-term wind speeds using Eq. (7). [31]

The Mathcad Software 2001*i* programme of MathSoft Engineering & Education, Inc. [30] was used for the application of this method.

3. Proposed method

3.1. Bayesian network

Probabilistic networks are probability-based intelligent systems that use models which allow problems with uncertainty to be tackled [32] and which can involve a high number of variables [19,21,22]. Probabilistic networks use graphs [23] and probability functions to define models that meet a set of dependency relationships between the variables. Depending on the type of graph employed (directed, undirected, mixed) and the means of establishing the dependency relationships in that graph, different types of probabilistic networks are obtained. In this paper, we propose the use of Bayesian networks (BNs). BNs (directed graphs) are more complex than Markov networks (undirected graphs) [32], but also more powerful as they allow more general relationships of dependency [23].

Let $U = (X_1, \ldots, X_N)$ be a finite set of random variables. Let us suppose that these variables are the wind speeds and wind directions recorded over a specific period of time at a set of weather stations installed in a given region. A Bayesian network over the set of variables U is a model based on a pair, BN = (DAG, Θ), that relates the set of variables of U. The DAG is a directed acyclic graph[1] (see Figs. 10–13), where each node or vertice represents one of the random variables $X_1, \ldots, X_N$ and each directed edge (arrow) between two nodes represents the probabilistic relationship between the variables that it connects. That is, the DAG defines the structure of the Bayesian network. The absence of an edge between two nodes implies that there is no direct probabilistic dependence between those nodes or variables. If an edge does join node A with another node B, then A is called a parent of B and B a child of A. Normally the symbol π_i is used to indicate the parent nodes of the variable X_i.

The DAG encodes assumptions of independence. That is, each variable X_i is independent of its nondescendants given its parents in the DAG. The second component of the pair, known as Θ, represents the set of probability distributions $p(X_i/\pi_i)$ for each variable (from $i = 1$ to N) that quantifies the network. The structure of dependency/independency shown by the DAG can be expressed in terms of the joint probability distribution (JPD) through the product of the conditional distributions. That is, a BN defines a unique JPD over U given by Eq. (8) [32].

$$p(X_1, X_2, \ldots, X_N) = \prod_i p(X_i/\pi_i) \tag{8}$$

Depending on the discrete or continuous nature of the variables, the conditional probabilities in Eq. (8) are specific families. In this paper, of the three types of BN (Gaussian, multinomial and mixed) [23] that can in principle be considered, multinomial Bayesian networks will be used. That is, it is considered that all the variables are discrete and that, therefore, they have a finite number of possible states. In addition, the probability distributions associated with each variable (node) are given, either parametrically or numerically, by means of tables that assign numerical values to the different combinations of the variables.

3.2. Learning Bayesian networks

The dual nature of BNs gives rise to their learning being undertaken in a two-stage process [33]. The first step consists of learning the structure of the BN or, in other words, establishing from a dataset D[2] the dependency relationships between the variables and obtaining the graph that best represents those data. The second step consists of parametric learning or, in other words, obtaining the a priori and conditional probabilities required in accordance with the graph structure, the data and the type of BN chosen.

The set of Bayesian networks with N nodes is of superexponential order, so exhaustive listing of the set of networks to find the best candidate is not feasible. The search for the structure that optimizes the set of data is an NP-complete (untreatable) problem [34] and requires efficient algorithms [21] which, though they do not guarantee location of the optimum, do not have a high calculation cost. There are several learning methods, however, with the simplest being iterative search algorithms comprising two parts. One part measures the quality of each candidate network and the other part uses a search algorithm that explores the set of possible graphs with the aim of finding a good quality BN.

3.3. Using Bayesian network classifiers

Bayesian network classifiers [35] constitute one of the most successful applications of Bayesian networks. In this particular case of a Bayesian network there is one variable, which we call a class variable, which is the only variable that does not have parents in the structure, and a set of variables that we call attribute variables (Figs. 10–13). The purpose of classification is to correctly predict the value of the class variable C (for example, the wind speed at a specific candidate site) which can have k possible discrete values ($c_1 \ldots c_k$) (for example, 0.5 m s^{-1}, 1.5 m s^{-1}, 2.5 m s^{-1} ... Nb-0.5 m s^{-1}) given a set ($A_1 \ldots A_{N-1}$) of predictive variables or attribute variables (for example, wind speeds and directions at three reference stations), also discrete (for example, 0.5 m s^{-1}, 1.5 m s^{-1}, 2.5 m s^{-1}, ... Nb-0.5 m s^{-1}, 0°, 45°, 90°, ..., 315°). That is, the aim is to identify the most plausible value of the variable C and return it as a result of the classification. In the Bayesian context the most plausible hypothesis is that which has the maximum

[1] The graph has no cycles. That is, there is no direct path that begins and finishes on the same node.

[2] For example, the wind speeds and directions recorded in $m = N/2$ anemometer weather stations of a region over the short-term (*ST*).

Author's personal copy

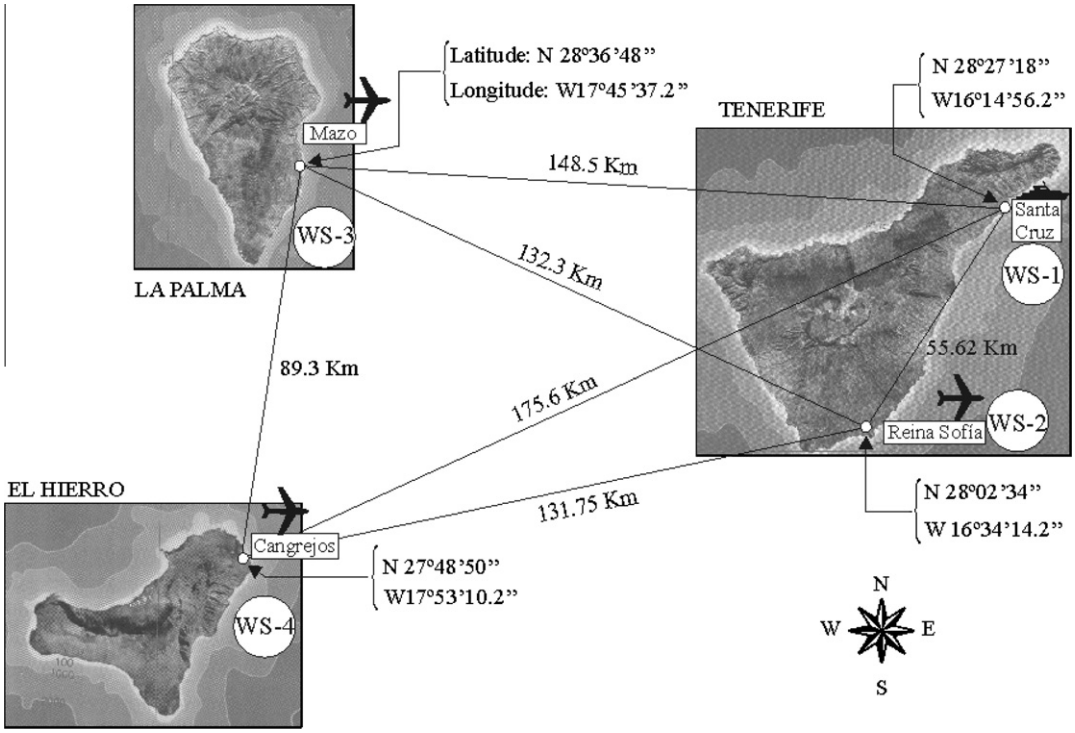

Fig. 1. Geographical location of the four anemometer weather stations used.

a posteriori probability given the attributes. This hypothesis is known as the maximum a posteriori (MAP) hypothesis. Thus, the value c_{MAP} to be returned will be the argument (arg) of the maximum a posteriori probability, Eq. (9)

$$c_{MAP} = \arg\max_{c \in \Omega_C} p(c/A_1 \ldots A_{N-1}) \tag{9}$$

where Ω_C is the set of discrete values that can take the class variable C and $p(c/A_1 \ldots A_{N-1})$ is the a posteriori probability of class c.

Calculation of $p(c/A_1 \ldots A_{N-1})$ can be performed using Bayes' theorem, Eq. (10)

$$\begin{aligned} c_{MAP} &= \arg\max_{c \in \Omega_C} p(c/A_1 \ldots A_{N-1}) \\ &= \arg\max_{c \in \Omega_C} \frac{p(A_1 \ldots A_{N-1}/c)p(c)}{p(A_1 \ldots A_{N-1})} \end{aligned} \tag{10}$$

where $p(c)$ is the a priori probability of the class c, $p(A_1 \ldots A_{N-1})$ the marginal probability and $p(A_1 \ldots A_{N-1}/c)$ the conditional probability of the class c.

Give that the divisor of Eq. (10) will be the same for all the categories, it can be eliminated, thereby obtaining Eq. (11)

$$c_{MAP} = \arg\max_{c \in \Omega_C} p(A_1 \ldots A_{N-1}/c)p(c) \tag{11}$$

Taking into account the Bayesian network, Eq. (8), Eq. (11) can be expressed in the following way, Eq. (12)

$$\begin{aligned} c_{MAP} &= \arg\max_{c \in \Omega_C} p(A_1 \ldots A_{N-1}/c)p(c) \\ &= \arg\max_{c \in \Omega_C} p(c) \prod_i p(A_i/\pi_i) \end{aligned} \tag{12}$$

Weka [19] has several measures of quality and search algorithms. Of the measures used by Weka [19] to assess the quality of the structure, in this paper we have chosen the Bayesian metric [23,34]. Likewise, of the various search algorithms available in Weka [19], in this paper we have used the so-called K2 algorithm [36], which performs a greedy search. The Bayesian network initially used is a Naive Bayes Network [19,35], namely a network

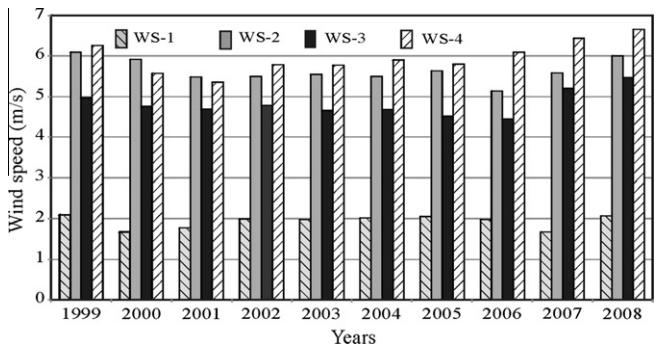

Fig. 2. Interannual evolution of the annual mean wind speeds at the four stations used.

with an edge from the classifier node or class node to each of the other nodes. The maximum number of possible parents for each node has been restricted to 2.

Once the network structure has been learnt, Weka [19] allows a choice as to how to learn the conditional probability tables. In this paper we have chosen the SimpleEstimator, available in Weka's easiest graphical user interface, called Explorer.

4. Meteorological data used

The meteorological data used in this paper (mean hourly wind speeds and directions) were recorded over the period 1999–2008 at four weather stations installed on three islands in the Canarian Archipelago (Spain) (Fig. 1). This information was provided by the State Meteorological Agency (Spanish initials: AEMET) of the Ministry of the Environment and Rural and Marine Environs of the Spanish Government.

Fig. 1 shows the names of the three islands (Tenerife, La Palma and El Hierro), their geographical location (latitude and longitude), the distances between them (in kms), the names of the weather stations (Santa Cruz Pier, Reina Sofía Airport, Mazo Airport and

Author's personal copy

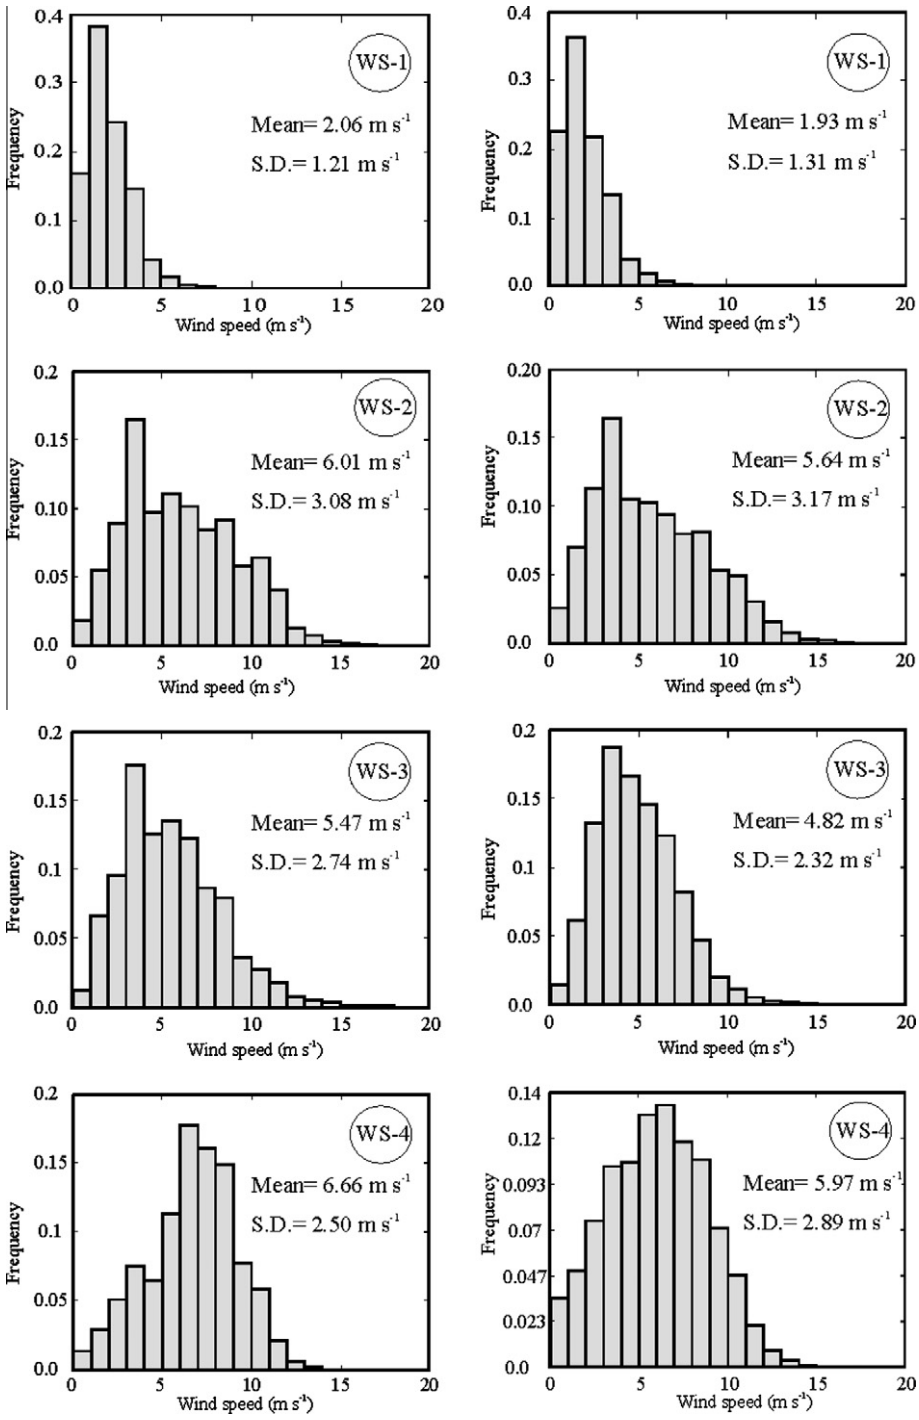

Fig. 3. Relative frequency histograms of the wind speed for the four stations used. The column on the left represents the histograms for 2008. The column on the right represents the histograms constructed with the wind speeds of the period 1999–2008.

Los Cangrejos Airport) and the references given to each weather station (WS-1, WS-2, WS-3 and WS-4). The height above ground level of each of the stations is 10 metres, with the exception of the WS-1 which has a lower height. Fig. 2 shows the evolution of the annual mean wind speeds for the four stations under consideration. Fig. 3 shows the relative frequency histograms of the wind speed for each of the stations with bin widths of 1 m s^{-1}. The column on the left represents the histograms for 2008, while the column on the right represents the histograms constructed with the wind speeds of all the years (1999–2008). Each histogram also shows the mean wind speed and standard deviation. Fig. 4 shows the wind roses for each of the stations.[3] The column on the left represents the wind roses for the year 2008, while the column on the right represents the wind roses constructed with the wind speeds and directions of all the years (1999–2008).

Table 1 shows the linear correlation coefficients between the wind speeds of the different stations. These coefficients were obtained for the wind speed data of 2008 and for the set of all wind

[3] In the analyses undertaken in this paper, eight direction sectors have been used. That is, the 360° have been divided into sectors of 45°.

Author's personal copy

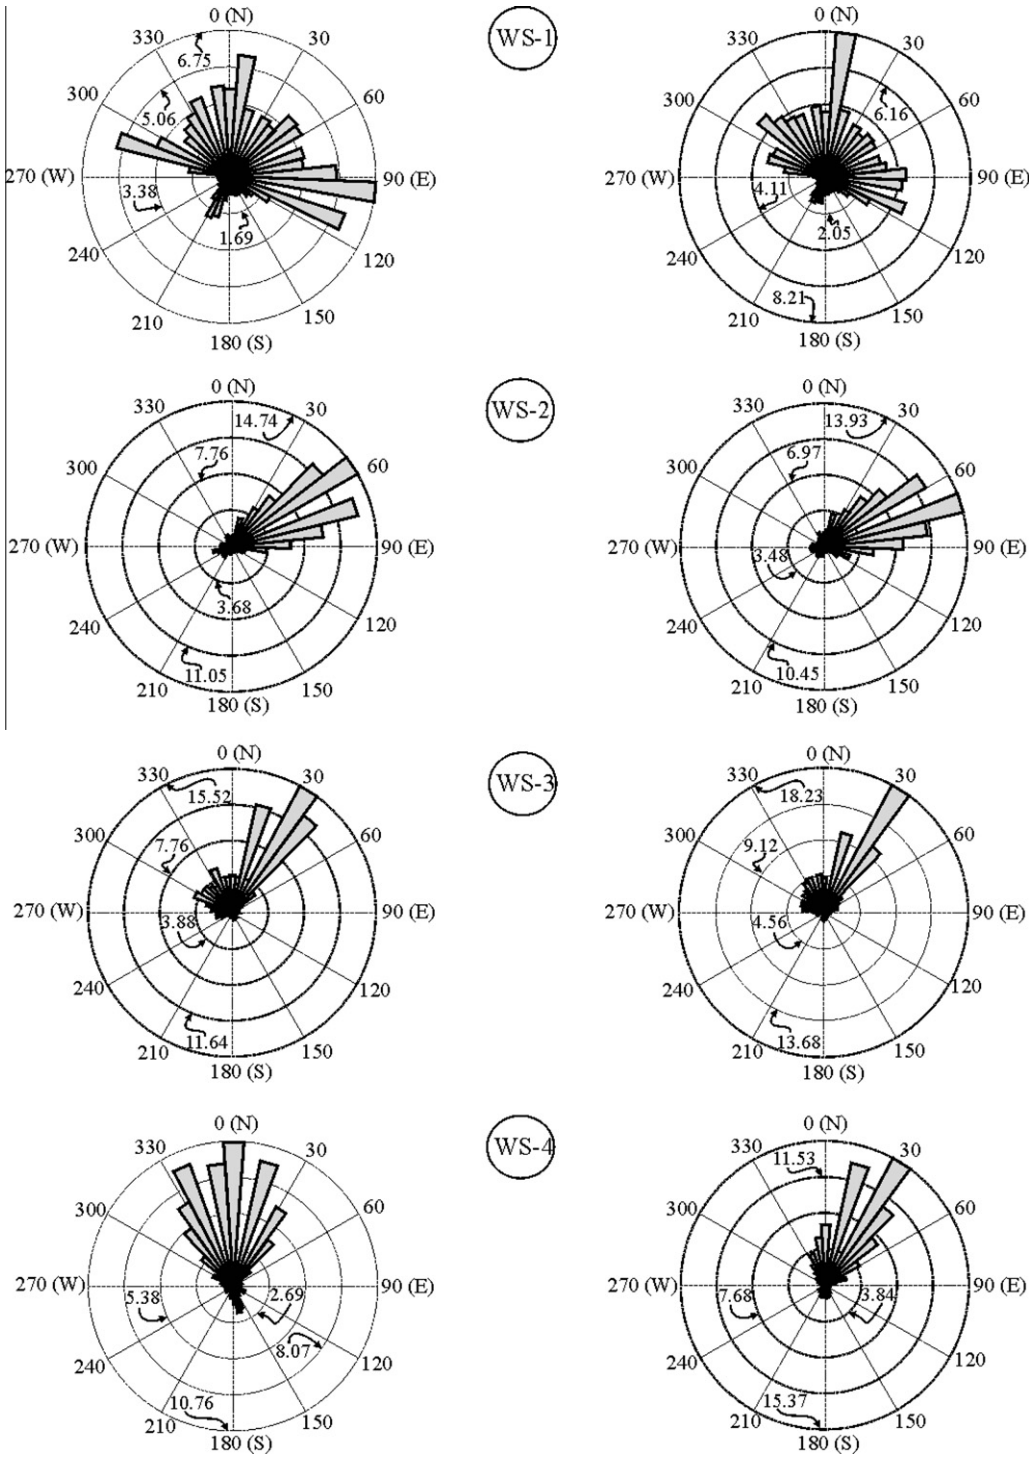

Fig. 4. Wind roses for each of the stations used. The column on the left represents the wind roses for the year 2008, while the column on the right represents the wind roses constructed with the wind speeds and directions of the period 1999–2008.

Table 1
Linear correlation coefficients between the wind speeds of the different anemometer weather stations.

	Data of the year 2008				Data of the period 1999–2008			
	WS-1	WS-2	WS-3	WS-4	WS-1	WS-2	WS-3	WS-4
WS-1	1	0.284	0.308	0.161	1	0.258	0.220	0.162
WS-2		1	0.319	0.248		1	0.377	0.259
WS-3			1	0.449			1	0.480
WS-4				1				1

Author's personal copy

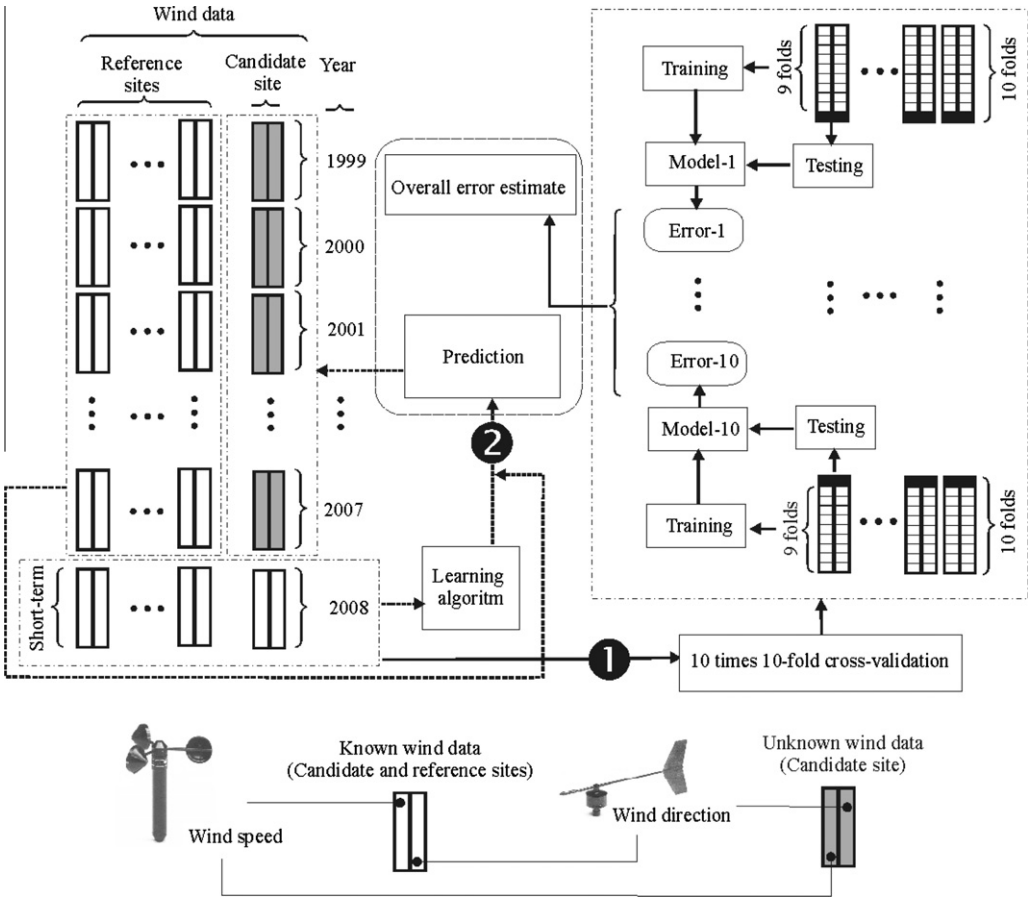

Fig. 5. Representative layout of the methodology used to learn and assess the models.

speed data (1999–2008). Despite the relatively short distances between the sites of the anemometer weather stations, these coefficients are low as a result of the orography of the areas where they are located.

5. Methodology

5.1. Model learning and evaluation methodology

Fig. 5 shows a representative layout of the problem we are dealing with. It can be seen that there is a candidate site for which a short period of mean hourly wind data is available (in our case, for the year 2008) and various reference stations (in our case, a maximum of three) for which mean hourly wind speed and direction data are available for a long period of time (in our case, 10 years: 1999–2008). Using the models described above in Sections 2 and 3 the objective is to estimate the wind speeds at the candidate station for the unknown long-term period. For this purpose, models have to be constructed and evaluated from the set of known data recorded over the same period of time at the weather stations in question (in our case, a maximum of four stations and a minimum of two). That is, using the wind data of the short time period (in our case, for the year 2008).

The model evaluation technique used was the 10-fold cross-validation method[4] (process shown in Fig. 5 with the number 1 enclosed in a circle). Using this technique, the data for the year 2008 are divided into ten parts. One part is used for the test dataset, while model training is performed with the data of the nine remaining parts. This is used to predict the result of the data of the part reserved for the test. This process is repeated ten times, on each occasion a different part being set aside for the test dataset. Thus, ten models are built and ten independent errors obtained, one for each constructed model. Finally, using all the data of the short period as a training dataset, a model is constructed (process shown in Fig. 5 with the number 2 enclosed in a circle) which is used to predict the unknown data of the candidate station. The error used to estimate this model will be the arithmetic mean of the ten errors obtained with the cross-validation.

5.2. Analysis methodology

The analysis procedure comprises two stages. In the first stage of the methodology procedure used in this paper, the different models that can be generated with the proposed method (Bayesian networks) and with the methods used for comparison purposes (linear regression method and vector regression method) are evaluated for each weather station. This evaluation consists of comparing the errors generated by the models using cross-validation (Fig. 5). These errors assess the efficiency of each method in the estimation of the cumulative frequency histograms of wind speed and are measured with the metrics as indicated in Section 7.

The number of models that can be generated with Bayesian networks, for each of the four weather stations, depends on the number of reference stations chosen. Thus, the number of models that can be constructed for each candidate station is obtained from the combination $C(nr, r)$ of nr reference stations taken r at a time Eq. (13)

[4] 10-fold cross-validation has become the standard method in practical terms [19].

Author's personal copy

$$C(nr, r) = \binom{nr}{R} = \frac{nr!}{r!(nr-r)!} \tag{13}$$

One model will be obtained from taking the three reference stations at a time, other models will be combinations of the three stations taken two at a time and the remaining models will be combinations of the three stations taken one at a time. Thus, one model will be obtained with three reference stations, three models with two reference stations and three models with one reference station. The use of a high number of reference stations does not necessarily imply that a better model will be obtained. The models may be sensitive to the presence of redundant or irrelevant variables. With this in mind, the idea is to analyse models with different combinations of reference stations. The number of models obtained with the chosen MCP comparison methods will be three for each method and station.

In the second stage of the procedure, firstly the models of each station are selected which, according to the metrics employed, generated the least errors. That is, of the models generated with BN, the one using three reference stations, the best of the models generated with two reference stations and the best of the models generated with one reference station are selected. With respect to the MCP comparison models, the best one for each method and weather station is chosen. Secondly, using the selected models, estimation is made of the long-term wind speed frequency histograms for the four candidate stations. Following this, the estimated values are compared with the available or long-term observed values for these candidate stations. The parameters analysed in this comparison are indicated in Section 6 and the metrics used in the evaluation are indicated in Section 7.

6. Parameters estimated by the method of bins

Among the methods which are normally used to estimate the energy output of a wind turbine subject to a given wind regime there are static or probabilistic methods [27]. Static methods are recommended when the objective is to confirm a site as a potential candidate for the location of a wind farm. Within this group of methods is found the method of bins. In this method the wind speed data are separated into Nb bins of width w, which is usually 1 m s^{-1}. In the case of wind direction data the classification interval is usually a sector of 30° or 45°. By determining the relative frequency at which the wind speed blows in each bin the frequency histogram can be plotted (Fig. 3). Likewise, the wind rose diagram can be constructed, which shows the azimuthal distribution of the wind direction (Fig. 4).

The mean wind power density $\overline{P}$ [26] is an indicator of the size of the local wind energy resource. If the air density ρ is considered to be constant and equal to its mean value[5] and the values of v_i (mid points of the wind speed bin widths) have units of m s^{-1}, then the value of $\overline{P}$, in w m^{-2}, is given by Eq. (14). In Eq. (14), f_i is the absolute frequency of the wind speed in each bin i.

$$\overline{P} = \frac{1}{2}\bar{\rho}\frac{\sum_{i=1}^{Nb} f_i v_i^3}{\sum_{i=1}^{Nb} f_i} \tag{14}$$

As stated by Hau [37], a wind turbine's power curve, as specified by the manufacturer, is the basis for energy output calculation from the point of view of the prospective buyer. The power curve of a wind turbine PWT (v, ρ) depends on the wind speed v and air density ρ [26]. However, most wind turbine manufacturers only publish the power curves of their wind turbines for an air density of 1.225 kg m^{-3}. This assumption simplifies the calculation of the mean power output $\overline{P}_{WT}$ for a wind turbine in a given wind regime, Eq. (15).[6]

In this paper, the wind turbine power output estimation for each value of v is carried out through interpolation of the values of the tables provided by the manufacturers. As the power curves are quite smooth they can be approximated by means of cubic spline interpolation [38]. Cubic spline interpolation lets you pass a curve through a set of points in such a way that the first and second derivatives of the curve are continuous across each point. This curve is assembled by taking three adjacent points and constructing a cubic polynomial passing through those points. These cubic polynomials are then strung together to form the completed curve.

$$\overline{P}_{WT} = \frac{\sum_{i=1}^{Nb} f_i PWT(v_i)}{\sum_{i=1}^{Nb} f_i} \tag{15}$$

7. Evaluation metrics used

In order to evaluate the goodness-of-fit of each of the models different metrics are proposed. Each of the metrics tries to characterise the correct estimation of one characteristic of the wind regime. Thus, the metric $M1$ evaluates the long-term mean wind power density, while $M2$ and $M3$ the long-term mean energy output of wind turbines of 330 kW and 800 kW rated power, respectively. These metrics are defined by Eq. (16) and (17), where the subscript "p" means predicted and the subscript "o" observed.

$$M1 = \frac{(\overline{P})_p}{(\overline{P})_o} \tag{16}$$

$$M2 = \frac{(\overline{P}_{WT-330})_p}{(\overline{P}_{WT-330})_o} \qquad M3 = \frac{(\overline{P}_{WT-800})_p}{(\overline{P}_{WT-800})_o} \tag{17}$$

Likewise, in order to evaluate the efficiency of each method in the estimation of the wind speed frequency histogram various metrics have been proposed [19]. These are the mean absolute error (MAE), the relative absolute error (RAE), the root mean square error (RMSE) and the root relative square error (RRSE). In the following equations, F_i is the value of the observed (i.e. expected) cumulative frequency, $\widehat{F}_i$ is the modelled (i.e. predicted) cumulative frequency (where i = 1 to Nb bins) and $\overline{F}$ is the mean of the observed cumulative frequencies.

$$\text{MAE} = \frac{1}{Nb}\sum_{i=1}^{Nb}\left|\widehat{F}_i - F_i\right| \tag{18}$$

$$\text{RAE} = \frac{\sum_{i=1}^{Nb}\left|\widehat{F}_i - F_i\right|}{\sum_{i=1}^{Nb}\left|F_i - \overline{F}\right|} \tag{19}$$

$$\text{RMSE} = \sqrt{\frac{1}{Nb}\sum_{i=1}^{Nb}\left(\widehat{F}_i - F_i\right)^2} \tag{20}$$

$$\text{RRSE} = \sqrt{\frac{\sum_{i=1}^{Nb}\left(\widehat{F}_i - F_i\right)^2}{\sum_{i=1}^{Nb}\left(F_i - \overline{F}\right)^2}} \tag{21}$$

8. Analysis of results

Figs. 6–9 show the errors obtained for each of the four stations following the first stage of the analysis methodology described in Section 5.2. A value equal to zero for these metrics would indicate

[5] A typical value used in all the literature consulted is $\bar{\rho} = 1.225$ kg m^{-3}, corresponding to standard conditions (sea-level, 15°C).

[6] To use Eq. (15) no extrapolation model has been used [3] of the wind speed at the wind turbines' rotor hub height. This has been done to avoid possible errors that such extrapolation models could introduce into this study.

Author's personal copy

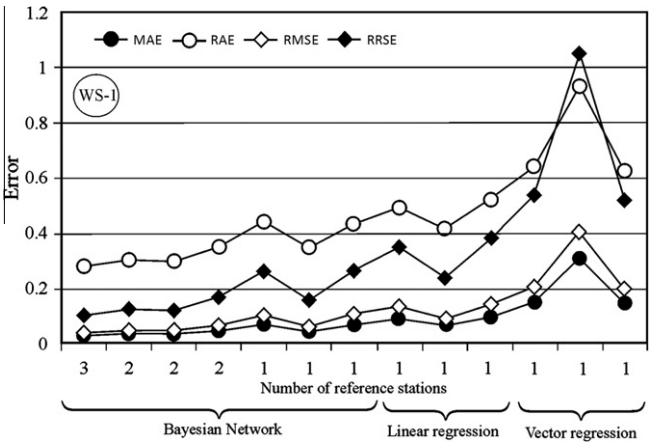

Fig. 6. Errors obtained with the different models of the WS-1 station in the first stage of the methodology process used.

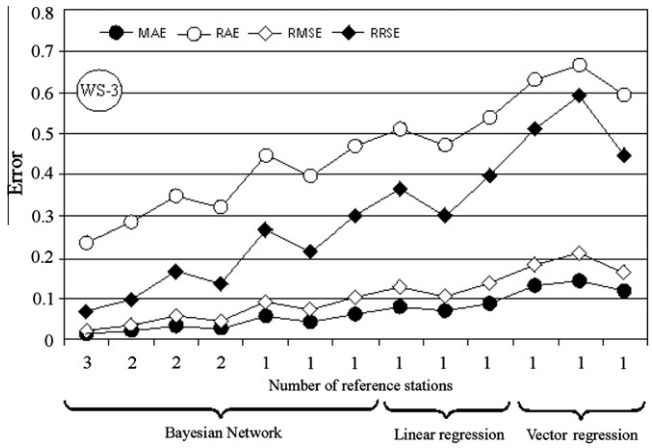

Fig. 8. Errors obtained with the different models of the WS-3 station in the first stage of the methodology process used.

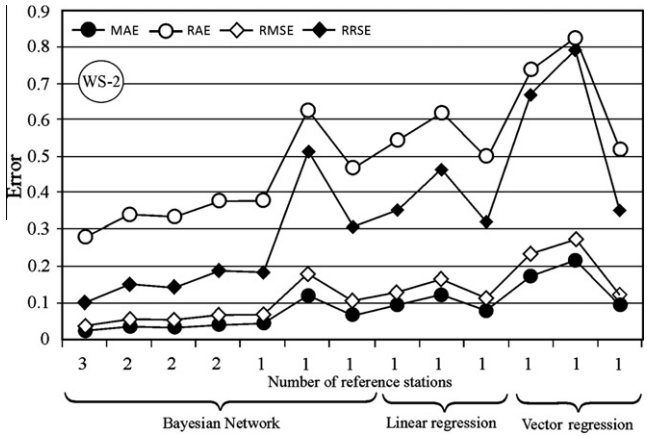

Fig. 7. Errors obtained with the different models of the WS-2 station in the first stage of the methodology process used.

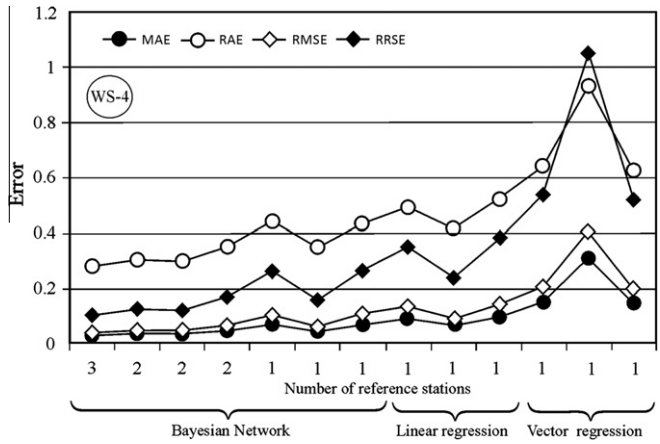

Fig. 9. Errors obtained with the different models of the WS-4 station in the first stage of the methodology process used.

a correct estimation of the cumulative wind speed frequency distribution.

In the four stations analysed it can be seen that the BN method with three reference stations (BN-3) has given the least errors, regardless of the metric employed. The BN models with two reference stations (BN-2), with the exception of one WS-4 model and one WS-1 model, gave less errors than the BNs with one reference station (BN-1). The comparison methods used behaved worse in most of the cases analysed than the proposed BN models. The worst behaviour, in most cases, came from the vector regression method (VR).

In accordance with the second stage of the methodology described in Section 5.2, the models were selected which in the first stage, according to Figs. 6–9, gave the least errors in the estimation of the cumulative frequency histograms of the wind speed. Table 2 shows the models which behaved best in the first stage. Given the limited number of stations analysed and the low and similar correlation coefficients between them (Table 1), no clear conclusions can be drawn about the influence of the correlation coefficient on the results obtained. Figs. 10–13 show the graphs of the Bayesian network models that gave the least errors. The graphs of these BNs represent the qualitative knowledge of the models. The graphs

Table 2
Models with the best behaviour in the first stage of the methodology process followed.

Candidate station	Models				
	BN			LR	VR
	Number of reference stations				
	3	2	1	1	1
WS-1	WS-2; WS-3; WS-4	WS-2; WS-3	WS-2	WS-2	WS-4
WS-2	WS-1; WS-3; WS-4	WS-1; WS-3	WS-3	WS-1	WS-1
WS-3	WS-1; WS-2; WS-4	WS-1; WS-4	WS-4	WS-4	WS-2
WS-4	WS-1; WS-2; WS-3	WS-2; WS-3	WS-3	WS-3	WS-2

Author's personal copy

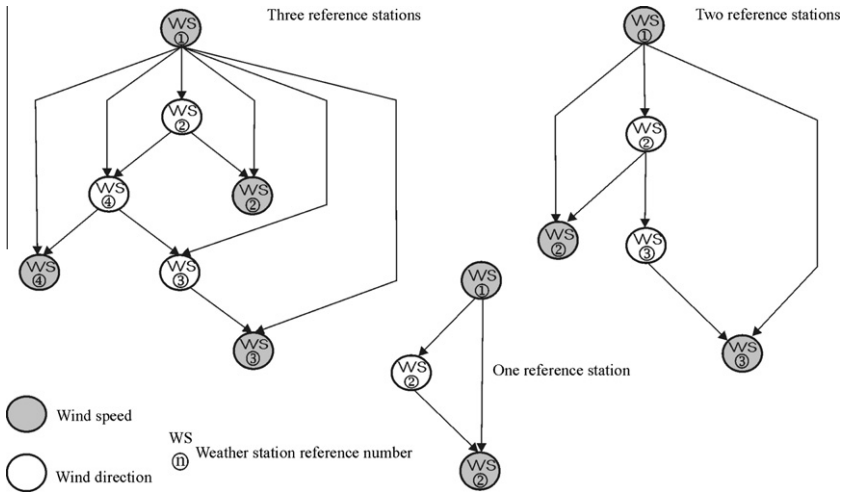

Fig. 10. Graphs of the models of selected Bayesian networks of station WS-1.

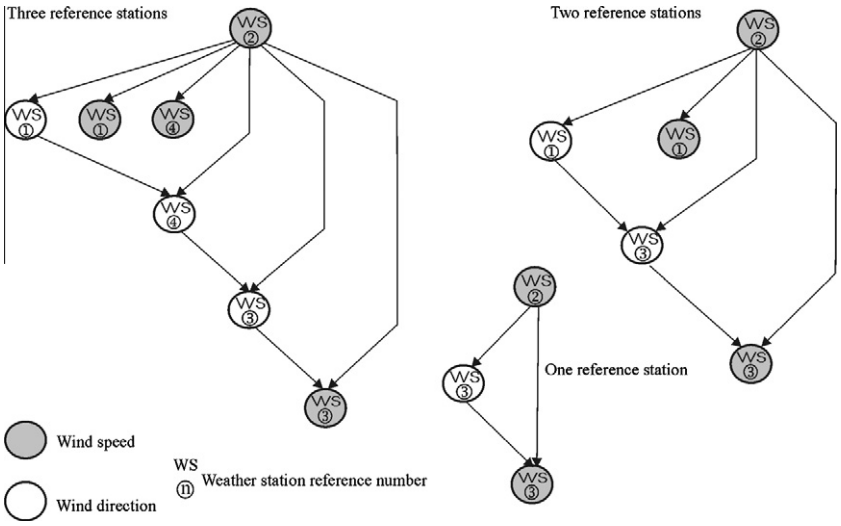

Fig. 11. Graphs of the models of selected Bayesian networks of station WS-2.

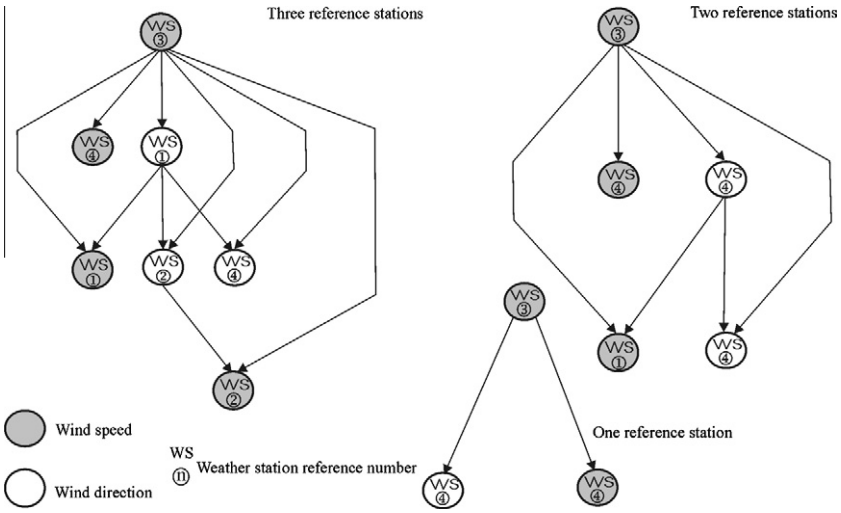

Fig. 12. Graphs of the models of selected Bayesian networks of station WS-3.

Author's personal copy

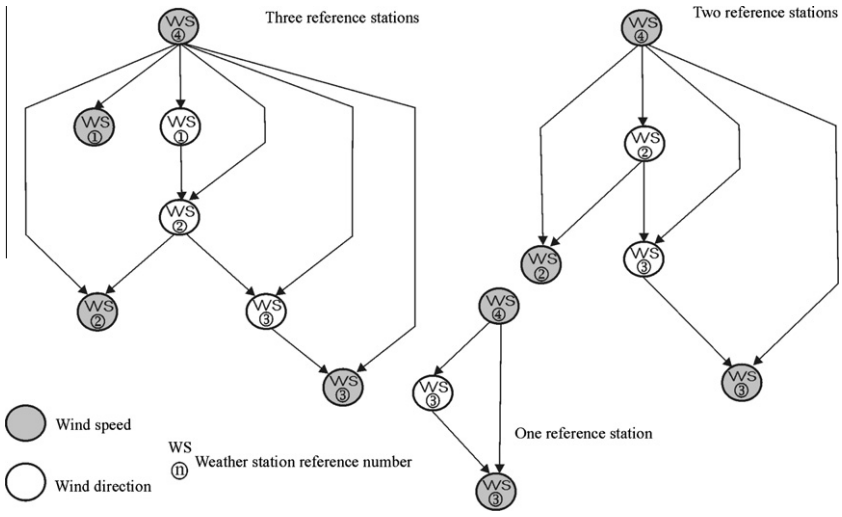

Fig. 13. Graphs of the models of selected Bayesian networks of station WS-4.

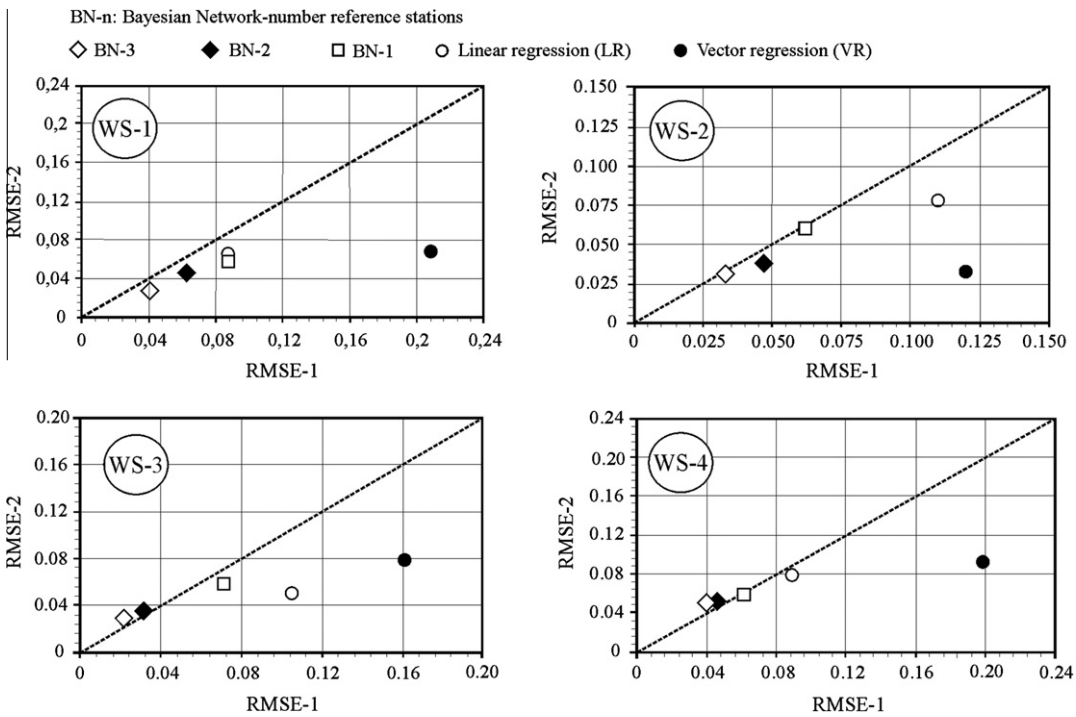

Fig. 14. RMSE metric of the errors committed in the estimation of the long-term wind speed frequency histograms of the four stations, as a function of the RMSE metric of the errors obtained in the first stage of evaluation of the models.

show the independency/dependency relationships between the variables that make up the models.

Using the models indicated in Table 2 the long-term wind speed frequency histograms of the four stations have been estimated and the errors of this estimation have been calculated. In order to compare the errors committed in the first stage with those arising in the second stage, the RMSE[7] metric of those errors is represented in Fig. 14 as a function of the errors obtained in the first stage of the evaluation of the models. It can be seen in Fig. 14 that the models obtained display a high power of generalisation. It can be observed that the errors obtained in stage 1 are very similar to the errors committed in the long-term prediction. Some models, basically the models used for comparison, even show fewer errors in the prediction stage than in stage 1. It can be seen that the Bayesian network models with three and two reference stations display, as in the first stage (Figs. 6–9), the best fits to the cumulative wind frequency histograms.

Table 3 shows the metrics $M1$–$M3$ defined in Section 6. Values of these metrics equal to 1 would indicate a correct prediction. It can be seen in Table 3 that the Bayesian network models with three reference stations have provided in all the stations, with the exception of the WS-2, a better prediction of the mean wind power density than the other models used. The Bayesian network models with three reference stations (BN-3) have provided in all the stations a better prediction of the mean electrical power obtainable from the wind with the two wind turbines selected than the other models used. Likewise, the Bayesian network models

[7] In order to simplify the demonstration the RMSE metric has been chosen. The behaviour of the other metrics was similar.

Author's personal copy

Table 3
Summary of the metrics used to evaluate the degree of prediction of the mean power density and the long-term mean electrical power obtainable from the wind using the wind turbines selected.

Metric	Models	Candidate weather stations			
		WS-1	WS-2	WS-3	WS-4
M1	BN-3	0.741	0.881	0.963	0.866
	BN-2	0.584	0.834	0.888	0.843
	BN-1	0.542	1.045	0.635	0.777
	LR	0.635	0.714	0.797	0.831
	VR	0.337	0.715	0.514	0.464
M2	BN-3	0.663	0.982	0.942	0.954
	BN-2	0.465	0.939	0.88	0.931
	BN-1	0.408	1.192	0.639	0.861
	LR	0.489	0.805	0.81	0.919
	VR	0.208	0.763	0.503	0.496
M3	BN-3	0.708	0.966	0.952	0.93
	BN-2	0.533	0.921	0.887	0.908
	BN-1	0.484	1.162	0.645	0.839
	LR	0.57	0.789	0.813	0.895
	VR	0.282	0.755	0.514	0.494

with two reference stations (BN-2) have provided in all the stations, with the exception of the WS-1,[8] a better prediction of the mean electrical power obtainable from the wind with the two wind turbines selected than the other models used.

9. Conclusions

This paper has presented an application of probabilistic Bayesian networks to the estimation of long-term wind speed frequency histograms of stations with only short-term wind data measurements. The proposed Bayesian network models allow the use of multiple reference stations with a long history of wind speed and wind direction measurements. That is, they can involve and make use of regional information of the wind resource. This method, using graphic representation of the models, constitutes an attractive tool for the specification of the quantitative knowledge of those models. The graphs of the Bayesian networks express the dependency/independency relationships between the variables that make up the models. The proposed model can be an alternative to MCP models that employ linear regressions to relate the wind speeds between a candidate station and a reference station. As a result of the application of the Bayesian network model proposed in this paper to the data for wind speed and wind direction recorded at four weather stations in the Canarian Archipelago, the following conclusions are reached:

(a) For the four stations analysed the BN models with three (BN-3) and two (BN-2) reference stations gave fewer errors than the reference MCPs used, independently of the metric employed in the estimation of the long-term cumulative wind frequency histograms.
(b) The BN-3 and BN-2 models obtained display a high power of generalisation. The errors obtained in the training stage are very similar to the errors committed in the long-term prediction.
(c) The Bayesian network models with three reference stations (BN-3) have provided for all the stations a better prediction of the mean electrical power obtainable from the wind with the two selected wind turbines than the other models used.

[8] As can be seen in Fig. 3, the wind speed in the WS-1 is very low. It has low wind frequencies above the start-up speed of the selected wind turbines.

References

[1] Hiester TR, Pennell WT. The siting handbook for large wind energy systems. 1st ed. New York: WindBook; 1981.
[2] Putnam PC. Power from the wind. 1st ed. New York: Van Nostrand Reinhold Company; 1948.
[3] Koeppl GW. Putnam's power from the wind. 2nd ed. New York: Van Nostrand Reinhold Company; 1982.
[4] Justus CG, Mani K, Mikhail AS. Interannual and month-to-month variations of wind speed. J Appl Meteorol 1979;18:913–20.
[5] Conrad V, Pollack LW. Methods in climatology. 2nd ed. Cambridge (MA): Harvard University Press; 1962.
[6] Daniels PA, Schroede TA. Siting large wind turbines in Hawaii. Wind Eng 1988;12:302–30.
[7] Carta JA, González J. Self-sufficient energy supply for isolated communities: wind-diesel systems in the Canary Islands. Energy J 2001;22:115–45.
[8] Aspliden CI, Elliott DL, Wendell LL. Resources assessment method, siting, and performance evaluation. In: Guzzi R, Justus CG, editors. Physical climatology for solar and wind energy. New Jersey: World Scientific; 1988. p. 321–76.
[9] Spera DA. Wind turbine technology. 3rd ed. New York: ASME Press; 1995.
[10] García-Rojo R. Algorithm for the estimation of the long-term wind climate at a meteorological mast using a joint probabilistic approach. Wind Eng 2004;28:213–24.
[11] Bechrakis DA, Deane JP, McKeogh EJ. Wind resource assessment of an area using short term data correlated to a long term data set. Solar Energy 2004;76:725–32.
[12] Öztopal A. Artificial neural network approach to spatial estimation of wind velocity data. Energy Convers Manage 2006;47:395–406.
[13] Barros VR, Estevan EA. On the evaluation of wind power from short wind records. J Clim Appl Meteorol 1983;22:1116–23.
[14] Nielsen M, Landberg L, Mortensen NG, Barthelmie RJ, Joensen A. Application of the measure–correlate–predict approach for wind resources assessment. In: Helm P, Zervos A, editors. European wind energy conference. Wind energy for the new millennium. Munich: WIP-Renewable Energies; 2001. p. 773–6.
[15] Derrick A. Development of the measure–correlate–predict strategy for site assessment. In: Garrad AD, Palz W, Screller S, editors. European community wind energy conference. UK: HS Stephens and Associates; 1993. p. 681–5.
[16] Riedel V, Strack M. Robust approximation of functional relationships between meteorological data: alternative measure–correlate–predict algorithms. In: Helm P, Zervos A, editors. European wind energy conference. Wind energy for the new millennium. Munich: WIP-Renewable Energies; 2001. p. 806–9.
[17] Woods JC, Watson SJ. A new matrix method of predicting long-term wind roses with MCP. J Wind Eng Ind Aerodyn 1997;66:85–94.
[18] Sreevalsan E, Das SS, Sasikumar R, Ramesh MP. Wind farm site assessment using measure–correlate–predict (MCP) analysis. Wind Eng 2007;31:111–6.
[19] Witten IH, Frank E. Data mining. 2nd ed. San Francisco: Elsevier; 2005.
[20] Cofiño AS, Gutiérrez JM, Jakubiak B, Melonek M. Implementation of data mining techniques for meteorological applications. In: Zwieflholer W, editor. Proceedings of the tenth ECMWF work-shop on the use of high performance computing in meteorology: realizing teracomputing. UK: World Scientific Publishing; 2003. p. 56–271.
[21] Neapolitan RE. Learning Bayesian networks. 1st ed. New Jersey: Pearson Prentice Hall; 2004.
[22] Jensen FV, Nielsen TD. Bayesian networks and decision graphs. 2nd ed. New York: Springer; 2007.
[23] Castillo E, Gutiérrez JM, Hadi AS. Expert systems and probabilistic network models. 1st ed. New York: Springer-Verlag; 1997.
[24] Manwell JF, McGowan JG, Rogers AL. Wind energy explained. 1st ed. England: John Wiley & Sons, Ltd.; 2002.
[25] Carta JA, Ramírez P, Velázquez S. A review of wind speed probability distributions used in wind energy analysis: case studies in the Canary Islands. Renew Sustain Energy Rev 2009;13:933–55.
[26] Carta JA, Mentado D. A continuous bivariate model for wind power density and wind turbine energy output estimations. Energy Convers Manage 2007;48:420–32.
[27] Carta JA, Ramírez P, Velázquez S. Influence of the level of fit of a density probability function to wind-speed data on the WECS mean power output estimation. Energy Convers Manage 2008;49:2647–55.
[28] Enercon GmbH. Enercon wind turbines. Product overview. Germany: Enercon GmbH. <http://www.Enercon.de>.
[29] Draper NR, Smith H. Applied regression analysis. 1st ed. New York: John Wiley & Sons, Inc.; 1998.
[30] Kiryanov D. The Mathcad 2001*i* handbook. 1st ed. USA: Delmar Thomson Learning; 2002.
[31] Carta JA, Ramírez P, Bueno C. A joint probability density function of wind speed and direction for wind energy analysis. Energy Convers Manage 2008;49:1309–20.
[32] Pearl J. Probabilistic reasoning in intelligent systems: networks of plausible inference. 1st ed. San Francisco: Morgan Kaufmann; 1988.
[33] Chickering M, Geiger D, Heckerman D. Learning Bayesian networks. In: Ficher D, Lenk H, editors. Learning from data. Artificial intelligence and statistics. Springer-Verlag; 1996. p. 21–30.
[34] Heck D, Chickering M, Geiger D. Learning Bayesian networks: the combination of knowledge and statistical data. Mach Learn 1995;20:197–244.

Author's personal copy

[35] Friedman N, Geiger D, Goldszmidt. Bayesian networks classifiers. Mach Learn 1997;29:131–63.
[36] Cooper GF, Herskovitz E. A Bayesian method for the induction of probabilistic networks from data. Mach Learn 1992;9:309–47.
[37] Hau E. Wind turbines. Fundamentals, technologies, application, economics. Germany: Springer; 2000.
[38] Akai TJ. Applied numerical methods for engineers. 2nd ed. New York: John Wiley & Sons, Inc.; 1994.