

UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
Programa de Doctorado Tecnología Industrial
(Bienio 2008-2010)



TESIS DOCTORAL

DESARROLLO DE UN MODELO PARA LA PREDICCIÓN DE LA
POTENCIA ELÉCTRICA DE UN PARQUE EÓLICO MEDIANTE EL
EMPLEO DE LAS REDES NEURONALES ARTIFICIALES

Memoria presentada, en cumplimiento de los
requisitos para optar al grado de DOCTOR, por el
Ingeniero de Organización Industrial D. Ulises
Portero Ajenjo

Director: Dr. D. Sergio Velázquez Medina
Codirector: Dr. D. José Antonio Carta González

El Director,

El Codirector,

El Doctorando,

Las Palmas de Gran Canaria, Noviembre de 2015

Dedicatoria

A mi hijo Julio,

esa comprensión que has tenido durante el desarrollo de la Tesis te será devuelta.

A mi mujer Angélica,

por el apoyo anímico prestado en éste y demás proyectos de la vida.

Al resto de mi familia,

han ayudado siempre en lo que han considerado mejor para mi futuro.

AGRADECIMIENTOS

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

- Al Dr. D. Sergio Velázquez Medina (Director de la Tesis). Profesor de la Universidad de Las Palmas de Gran Canaria (ULPGC).
Muchas gracias por la confianza depositada en mí para el desarrollo de este proyecto que sin tu apoyo y dedicación no hubiese sido posible.
- Al Dr. D José Antonio Carta González (Director de la Tesis). Profesor de la Universidad de Las Palmas de Gran Canaria (ULPGC).
- 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.
- Al Instituto Tecnológico de Canarias (ITC), S.A. por facilitar toda aquella información que estuviera a su alcance para el desarrollo de la presente tesis y a sus trabajadores.
- Parque Eólico La Florida de SOSLAIRES CANARIAS, S.A.
- Parque Eólico Los Valles de Eólicas Lanzarote, S.L.

Índice de Contenidos

INDICE DE FIGURAS.....	VI
INDICE DE TABLAS.....	XI

1- Evolución, situación actual y perspectivas futuras de la energía eólica.

1.1 Introducción.....	3
1.2 Las Energías Renovables.....	4
1.3 La Energía Eólica.....	10
1.3.1 El Viento.....	10
1.4 Marco Normativo.....	15
1.5 Referencias.....	19

2.- Aprovechamiento del Recurso Eólico

2.1 Evolución del aprovechamiento de la energía eólica.....	23
2.1.1 A nivel mundial.....	30
2.1.2 En Europa.....	34
2.1.3 A nivel nacional.....	38
2.1.4 A nivel de la Región de Canarias.....	44
2.2 Referencias.....	52

3.- Predicción de la potencia eléctrica de origen eólico

3.1 Introducción.....	56
3.2 La variabilidad de la potencia eólica.....	60
3.3 Aspectos principales del problema de predicción de potencia eólica.....	66
3.3.1 Modelado del proceso de conversión de energía.....	67
3.3.2 Importancia de las predicciones para el operador del sistema eléctrico.....	69
3.4 Bibliografía de los modelos de predicción a corto plazo de la producción eléctrica de origen eólico.....	72
3.4.1 Evaluación de modelos de predicción.....	72

3.4.2 Familias de modelos de predicción de la producción eléctrica de origen eólica en el corto plazo	75
3.5 Error de la predicción de la potencia eólica.....	81
3.5.1 Definición del error de predicción.....	82
3.5.2 Evaluación del error orientada a la medida de parámetros.....	83
3.5.3 Evaluación del error orientada a la distribución del error.....	86
3.6. Beneficios y penalizaciones de la predicción eólica.....	88
3.6.1 Desvíos en la predicción.....	90
3.6.2 Exención del coste del desvío.....	92
3.7 Referencias.....	94
4.- Objetivo de la tesis	
4.1 Introducción.....	98
4.2 Objetivo General.....	99
4.3 Metodología.....	99
4.4 Referencias.....	100
5.- Estado del arte en la predicción de la potencia eléctrica de origen eólico	
5.1. Introducción.....	104
5.2. Predicción numérica del	104
5.2.1 Modelos atmosféricos de macro-escala globales.....	106
5.2.2 Modelos atmosféricos de macro-escala Regionales.....	107
5.2.3 Modelos atmosféricos meso-escalares y de micro-escala.....	108
5.2.4 Conclusiones.....	113
5.3 Técnicas utilizadas en los modelos de predicción eólica.....	114
5.3.1 Modelos físicos.....	115
5.3.2 Modelos estadísticos.....	117
5.3.2.1 MOS.....	118
5.3.2.2 Filtros de Kalman.....	119
5.3.2.3 Modelos ARIMA.....	120
5.3.2.4 Redes Neuronales Artificiales.....	120
5.3.2.5 Fuzzy Logic: Sistemas de Inferencia Difusa.....	123
5.3.2.6 Conclusiones.....	125
5.3.3 Comparación de modelos.....	126
5.4 La herramienta de predicción SIPREÓLICO.....	128
5.4.1 Datos de entrada.....	129
5.4.2 Modelos de predicción de Sipreólico.....	131
5.5 El proyecto ANEMOS.....	134

5.6 Descripción y características de los modelos de predicción existentes.....	136
5.6.1 Aeolis.....	138
5.6.2 Casandra.....	140
5.6.3 CENER.....	143
5.6.4 MeteoLógica.....	145
5.7 Otros modelos.....	147
5.7.1 Aleasoft.....	147
5.7.2 Garrad Hassan.....	149
5.7.3 Meteosim.....	153
5.7.4 EA2.....	154
5.8 Ejercicio de Predicción.....	156
5.9 Referencias.....	158

6.- Las Redes Neuronales

6.1 Introducción a las Redes Neuronales.....	165
6.2 Desarrollo histórico de las redes neuronales.....	169
6.3 Funcionamiento de una neurona biológica.....	171
6.4 Características de una red neuronal artificial.....	177
6.4.1 Notación.....	180
6.4.2 Funciones de transferencia.....	181
6.4.3 Tipología de una red.....	183
6.4.4 Aprendizaje de las Redes Neuronales.....	189
6.5 Principales tipos de Redes Neuronales.....	192
6.5.1 Perceptron.....	192
6.5.1.1 Antecedentes.....	192
6.5.1.2 Estructura de la red.....	196
6.5.2 Adaline.....	198
6.5.2.1 Antecedentes.....	198
6.5.2.2 Estructura de la red.....	199
6.5.3 Backpropagation.....	201
6.5.3.1 Antecedentes.....	201
6.5.3.2 Estructura de la red.....	203
6.5.3.3 Regla de aprendizaje.....	205
6.6 Referencias.....	218

7.- Influencia de la fiabilidad en la predicción a corto plazo de la potencia eléctrica producida por un parque eólico, en el coste de generación por MWh y en la planificación de las áreas eólicas. Un caso de estudio en las islas Canarias.

7.1 Introducción.....	222
7.2 Metodología.....	225
7.3 Datos Meteorológicos usados.....	230
7.4 Cálculos y análisis de resultados.....	231
7.4.1 Coste económico del desvío entre la potencia medida y la predicha.....	234
7.4.2 Estructura de coste de la energía generada por un aerogenerador.....	237
7.4.3 Precio de la Energía Eléctrica.....	238
7.4.4 Análisis de resultados.....	240
7.5 Los sistemas de hidrobombeo reversibles como medio para la gestión de los excedentes o déficits de energía eléctrica de origen	246
7.6 Conclusiones.....	246
7.7 Referencias.....	248

8.- Desarrollo de un Modelo Dinámico de curva de potencia de un parque eólico utilizando las Redes Neuronales Artificiales. Aplicación a dos parques eólicos de Canarias.

8.1 Introducción.....	254
8.2 Objetivo.....	254
8.3 Metodología.....	255
8.4 Datos de partida utilizados en el estudio.....	261
8.5 Arquitectura de las Redes Neuronales utilizadas.....	267
8.6 Discusión de los datos obtenidos.....	268
8.7 Conclusiones al capítulo.....	274
8.7 Referencias.....	276

9.- Análisis de la influencia de los datos de la capa de entrada de un modelo de Red Neuronal Artificial en la predicción a corto plazo de la potencia eléctrica de un parque eólico.

9.1 Introducción.....	279
9.2 Objetivo.....	282
9.3 Metodología.....	283

9.4 Datos de partida.....	288
9.5 Arquitectura de las Redes Neuronales utilizadas.....	291
9.6 Discusión de los resultados obtenidos.....	292
9.7 Conclusiones al capítulo.....	300
9.8 Referencias.....	302

10 Conclusiones de la Tesis y líneas de investigación futuras que se proponen.

10.1 Introducción.....	307
10.2 Aportaciones de la tesis.....	308
10.3 Conclusiones.....	310
10.4 Líneas de investigación futuras que se proponen.....	313

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

Artículo 1:

Título: "Sizing of a wind-hydro system using a reversible hydraulic facility with seawater. A case study in the Canary Islands"

Revista: Energy Conversion and Management, 106. 2015: pp. 1251-1263.

Artículo 2:

Título: Influence of the reliability of short-term electrical power forecasting for a wind farm on the generation cost per MWh. A case study in the Canary Islands

Revista: Renewable Energy & Power Quality Journal, 13. 2015; nº páginas 6.

ANEXO II: Código fuente de las FUNCIONES más importantes implementadas en Matlab durante la ejecución de la Tesis.

INDICE DE FIGURAS:

Figura 1.1: Participación de las distintas fuentes de energía en la generación eléctrica

Figura 1.2: Reparto de nueva potencia eólica instalada de los países de la UE a diciembre de 2012

Figura 1.3: Evolución de la producción eléctrica según fuentes energéticas

Figura 1.4: Mapa de la evolución de la energía renovable

Figura 1.5: Empleo generado por la Energía Eólica a nivel nacional

Figura 1.6: Principio de funcionamiento de un aerogenerador

Figura 1.7: Principales componentes de un aerogenerador

Figura 1.8: Evolución del tamaño de aerogeneradores

Figura 1.9: Escenario de la eficiencia energética adicional: Evolución de la capacidad eléctrica instalada según fuentes energéticas

Figura 2.1: Aprovechamiento de la Energía Eólica

Figura: 2.2: Reparto por promotores de la potencia instalada a finales de 2012

Figura: 2.3: Potencia instalada por los fabricantes a finales de 2012

Figura 2.4: Capacidad instalada a nivel mundial

Figura 2.5: Capacidad instalada a nivel mundial

Figura 2.6: Contribución continental en la capacidad total instalada [%]

Figura 2.7: Evolución y pronóstico de la capacidad total instalada

Figura 2.8: Capacidad instalada en Europa (GW)

Figura 2.9: Mapa eólico de Europa

Figura 2.10: Capacidad instalada en algunos países de Europa en 2010

Figura 2.11: Evolución anual de la potencia eólica acumulada en España (1998-2012)

Figura 2.12: Evolución de la potencia eólica instalada por Comunidades Autónomas (2004-2012)

Figura 2.13: Comparación entre la potencia eólica instalada y prevista para 2020 en España

Figura 2.14: Potencia eólica instalada en Canarias

Figura 2.15: Mapa de instalaciones eólicas en Canarias

Figura 2.16: Evolución de la potencia eólica instalada en Canarias

Figura 2.17: Comparativa de potencia eólica instalada

Figura 2.18. Comparación entre la potencia eólica instalada y prevista para 2015 en Canarias

Figura 3.1: Causas del viento a escala global

Figura 3.2: Espectro característico de Van der Hoven

Figura 3.3: Ejemplo de función de distribución de Weibull ajustada a las datos de viento en una zona

Figura 3.4: Curva de potencia característica de un aerogenerador

Figura 3.5: Curva de potencia estimada y medida de un parque eólica de 21MW en Dinamarca en un periodo de 2.000 horas

Figura 3.6: Histograma del error normalizado de predicciones de horizonte K=5 para el parque PE3

Figura 5.1: Modelo Global de Alemania con una resolución espacial de 60 x 60 km²

Figura 5.2: Dominio del modelo Local del Servicio Meteorológico Alemán con una resolución espacial de 7 x 7 km²

Figura 5.3: Anidamiento de dominios para la ejecución del modelo atmosférico MM5 con una elevada resolución espacial para una zona de La Rioja

Figura 5.4: Curva de potencia del aerogenerador G90-2.0 MW fabricado por Gamesa Corporación Tecnológica

Figura 5.5: Mejora en la predicción utilizando filtros de Kalman

Figura 5.6: Esquema básico de red neuronal utilizado en WPMS

Figura 5.7: Estructura de un sistema de inferencia difusa

Figura 5.8: Mejora del error de predicción (RMSE) de la velocidad de viento en el parque de Alaiz

Figura 5.9: Errores (RMSE) de las predicciones de viento para Alaiz de los modelos: MM5, MM5+CFD, MM5+LocalPred, MM5+CFD+MOS

Figura 5.10: Diagrama de funcionamiento de SIPREEÓLICO

Figura 5.11: Esquema del módulo de predicción de Sipreólico

Figura 5.12: Esquema de los modelos de predicción

Figura 5.13: Predicción de producción eólica nacional

Figura 5.14: Características del modelo Aeolis

Figura 5.15: Esquema de funcionamiento del modelo Casandra

Figura 5.16: Características del modelo CENER

Figura 5.17: Predicción regional de generación eólica en Alemania y observaciones en tiempo real

Figura 5.18: Características del modelo Meteorológica

- Figura 5.19: Esquema general de funcionamiento AleaSoft
- Figura 5.20: Características del modelo AleaSoft
- Figura 5.21: Ejemplo de serie temporal de una predicción de velocidad de viento, T+12 h
- Figura 5.22: Ejemplo de serie temporal de una predicción de energía, T + 12 h
- Figura 5.23: Características del modelo Garrad Hassan
- Figura 5.24: Características del modelo eWind
- Figura 5.25: Arquitectura del sistema EA2
-
- Figura 6.1: Neurona Biológica
- Figura 6.2: Neurona Real
- Figura 6.3: Cambios asociativos de las fuerzas sinápticas durante el aprendizaje
- Figura 6.5: Proceso de una sinapsis
- Figura 6.4: Comunicación entre neuronas
- Figura 6.5: Proceso de una sinapsis Comunicación entre neuronas
- Figura 6.6: Neurona Artificial
- Figura 6.7: De la neurona biológica a la neurona artificial
- Figura 6.8: Proceso de una red neuronal
- Figura 6.9: Neurona de una sola entrada
- Figura 6.10: Funciones (a) escalón, (b) rampa, (c y d) funciones sigmoides
- Figura 6.11: Neurona con múltiples entradas
- Figura 6.12: Neurona con múltiples entradas, notación abreviada
- Figura 6.13: Capa de S neuronas
- Figura 6.14: Red de tres capas
- Figura 6.15: Red de tres capas con notación abreviada
- Figura 6.16: Redes Recurrentes
- Figura 6.17: Bloque de retardo
- Figura 6.18: Bloque integrador
- Figura 6.19: Aprendizaje supervisado
- Figura 6.20: Aprendizaje no supervisado
- Figura 6.21: Secuencia del desarrollo de una aplicación basada en red neuronal artificial
- Figura 6.22: Modelo del Fotoperceptrón de Rosenblatt
- Figura 6.23: Esquema de conexiones de un Perceptrón sencillo
- Figura 6.24: Perceptrón según Minsky y Papera
- Figura 6.25: Perceptrón

Figura 6.26: Capacidad de decisión de las redes neuronales artificiales (perceptrón multicapa)

Figura 6.27: Estructura de una red Adaline

Figura 6.28: Adaline de una neurona y dos entradas

Figura 6.29: Características de decisión de una red tipo Adaline

Figura 6.30: Red de tres capas

Figura 6.31: Notación compacta de una red de tres capas

Figura 6.32: Disposición de una red sencilla de 3 capas

Figura 6.33: Superficie típica de error

Figura 6.34: Intervalo de la función t

Figura 6.35: Red utilizada para aproximar la función

Figura 7.1: Localización de las estaciones meteorológicas usadas (Velázquez et al., 2011b)

Figura 7.2: Distribuciones horarias medias porcentuales de la potencia eólica para cada uno de los meses del año

Figura 7.3: Distribución de la densidad de la potencia eólica media mensual

Figura 7.4: Distribución relativa porcentual de la energía eólica mensual

Figura 7.5: Coste medio mensual de la energía desviada

Figura 7.6: Precios de venta medios mensuales de la energía eléctrica (€/MWh)

Figura 7.7: Contribución del coste de desvío al coste de producción de la energía eléctrica por un aerogenerador

Figura 7.8: Coste total de producción de la energía eléctrica generada por un aerogenerador (COE)

Figura 7.9: Relación existente entre el coste de desvío específico (C_{de}) y los ingresos por Mwh(Pre)

Figura 7.10: Variación del rendimiento de la energía normalizada función del valor del NMAE

Figura 8.1: Fases de los procesos de estimación de las velocidades y direcciones del viento

Figura 8.2: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se utiliza únicamente en la capa de entrada la Velocidad y Dirección del viento de la estación de referencia del parque

Figura 8.3: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se incorpora, adicionalmente, los datos de velocidad y dirección de una estación ajena al parque eólico

Figura 8.4: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando en la capa de entrada se utiliza exclusivamente la información de velocidad y dirección del viento de una estación ajena al parque eólico

Figura 8.5: Distribución en planta del parque eólico WF-1 en Gran Canaria

Figura 8.6: Curva de funcionamiento del aerogenerador GAMESA G47/660kW

Figura 8.7: Ubicación del parque eólico WF-2 en Lanzarote

Figura 8.8: Curva de funcionamiento del aerogenerador GAMESA G52/850kW

Figura 8.9: Ubicación de las estaciones anemométricas (WS) y parques eólicos (WF) utilizados en el estudio

Figura 8.10: Rosas de los vientos de las estaciones de referencia de los parques eólicos WF-1 y WF-2, respectivamente

Figura 8.11: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-1

Figura 8.12: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-1

Figura 8.13: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-2

Figura 8.14: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-2

Figura 8.15: Resultados del IoA para la hipótesis 2. Casos particulares de los parques eólicos WF-1 y WF-2

Figura 8.16: Grado de similitud en la precisión de los modelos dinámicos calculados según las hipótesis 1 y 3

Figura 9.1: Metodología para la obtención de los modelos de predicción

Figura 9.2: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso A)

Figura 9.3: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso B)

Figura 9.4: Distribución en planta del parque eólico

Figura 9.5: Ubicación de las estaciones anemométricas (WS) y del parque eólico (WF)

Figura 9.6: MARE para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

Figura 9.7: Valor de R para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

Figura 9.8: Variación del MARE para los diferentes periodos de predicción. Caso de un horizonte temporal $t+24$

Figura 9.9: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN

Figura 9.10: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN.

Figura 9.11: Mejora experimentada por el MARE del modelo al incorporar una estación adicional a la capa de entrada de la ANN

Figura 9.12: Mejora experimentada por el R del modelo al incorporar una estación adicional a la capa de entrada de la ANN

INDICE DE TABLAS:

Tabla 2.1: Potencia eólica instalada en los distintos países (MW)

Tabla 2.2: Potencia eólica instalada por Comunidades Autónomas 2012

Tabla 2.3: Comparativa de la potencia eólica instalada (2005-2010) y nueva previsión de potencia (2011-2015), con la previsión PECAN (2005-2015).CANARIAS

Tabla 2.4: Potencia instalada en Canarias en el año 2015

Tabla 3.1: Resumen de características de modelos de predicción de la primera familia

Tabla 3.2: Resumen de características de modelos de predicción de la segunda familia

Tabla 5.1: Sistemas de predicción numérica del tiempo en Europa

Tabla 6.1: Resumen de los aspectos más relevantes en el entorno de la neurona artificial

Tabla 6.2: Clasificación de las Redes Neuronales según tipo de aprendizaje y arquitectura

Tabla 7.1: Coste medio horario, para cada mes, de la energía desviada (€/MWh)

Tabla 7.2: Evolución del precio medio aritmético de la energía eléctrica en el mercado libre español

Tabla 8.1: Estaciones meteorológicas utilizadas en el estudio

Tabla 8.2: Parques eólicos utilizados para el estudio

Tabla 8.3: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas

Tabla 8.4: Resultados de la eficiencia de los modelos según la hipótesis 1

Tabla 8.5: Caso para la hipótesis 2 y WF-1

Tabla 9.1: Información de las estaciones meteorológicas utilizadas en el estudio

Tabla 9.2: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2008

NOMENCLATURA

AEE	Asociación Empresarial Eólica
AEMET	Agencia estatal de meteorología
ANEMOS	Predicción Eólica en la Unión Europea
ANN, RNA	Siglas en inglés de Red Neuronal Artificial
ARPS	Sistema de predicción regional avanzado
BN	Redes Bayesianas
CC	Coefficiente de correlación entre las velocidades de dos estaciones anemométricas
Cde	Coste de desvío medio por unidad de energía generada por un aerogenerador (en €/MWhproduced)
\overline{Cd}_m	Coste específico medio, para el mes "m", por unidad de energía desviada (en €/MWhdesviada)
\overline{Cd}	Coste medio por unidad de energía desviada (en €/MWhdesviada)
CENER	Centro nacional de energías renovables
CFD	Modelo de dinámica de fluidos
CI	Coste de la inversión inicial de un aerogenerador (en Euros)
CIEMAT	Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas
CO&M	Coste del mantenimiento y operación anual. (en Euros)
COAMPS	US Navy's Coupled Ocean/Sistema de predicción atmosférica de mesoescala
COE	Coste específico de la energía producida por un aerogenerador. (en €/MWh)
DWFPC	Siglas en inglés de Modelo Dinámico de curva de potencia de parque eólico. Este modelo ha sido uno de los desarrollados en la presente Tesis.
ECMWF	European Centre for Medium-Range Weather Forecasts
EMAE	Error medio absoluto de estado
EMAP	Error medio absoluto de producción
EP	Rendimiento energético (en MWh/MW)
GFS	Sistema de Predicción Global
HIRLAM	Modelo de área limitada de gran resolución
IDAE	Instituto español para la diversificación y ahorro de energía
INC	Venta de la energía eléctrica producida por el parque eólico
IoA	Índice de Acuerdo entre los valores estimados y reales. Métrica para medir la

Nomenclatura

	precisión de los modelos
MAE	Error Absoluto Medio
MARE	Error relativo absoluto medio
MCP	Medir-Correlacionar-predecir
MEMO	Modelos de Mesoescala
MLPs	Multicapas Perceptrons
MM5	Modelo de Mesoescala, Version 5
MOS	Modelos de salida estadística
NCEP	Centro Nacional para la predicción ambiental
NEP	Rendimiento Energético Normalizado (en MWh/MW)
NMAE	Error absoluto medio normalizado. Es la relación entre el error absoluto medio y la potencia nominal del parque eólico
NSDE	Desviación estándar del NMAE
NWP	Predicción Numérica del Tiempo
OMEL	Operador del Mercado Eléctrico Español
OMM	Organización Mundial Meteorológica
P	Potencia eléctrica instalada en el parque eólico
Pre	Precio específico medio de la energía eléctrica. (en €/MWh)
PSU/NCA	Universidad Estatal de Pennsylvania y el Centro Nacional para la Investigación Atmosférica
R	Coefficiente de correlación entre los datos estimados por los modelos y los reales
REE	Red Eléctrica de España
SDE	Desviación Estándar
ULPGC	Universidad de Las Palmas de Gran Canaria
WF	Parque eólico
WPPT	Herramienta de predicción de potencia eólica
WPMS	
WRF	Modelo de Predicción Meteorológico
WS	Estación Meteorológica

CAPÍTULO 1

Evolución, situación actual y perspectivas futuras de la energía eólica.

INDICE

1. Introducción.....	3
1.2 Las Energías Renovables.....	4
1.3 La Energía Eólica.....	10
1.3.1 El Viento.....	10
1.4 Marco Normativo.....	15
1.5 Referencias.....	19

INDICE DE FIGURAS:

Figura 1.1: Participación de las distintas fuentes de energía en la generación eléctrica

Figura 1.2: Reparto de nueva potencia eólica instalada de los países de la UE a diciembre de 2012

Figura 1.3: Evolución de la producción eléctrica según fuentes energéticas

Figura 1.4: Mapa de la evolución de la energía renovable

Figura 1.5: Empleo generado por la Energía Eólica a nivel nacional

Figura 1.6: Principio de funcionamiento de un aerogenerador

Figura 1.7: Principales componentes de un aerogenerador

Figura 1.8: Evolución del tamaño de aerogeneradores

Figura 1.9: Escenario de la eficiencia energética adicional: Evolución de la capacidad eléctrica instalada según fuentes energéticas

1.1 Introducción

La evolución de la raza humana, así como la de su entorno (plantas, animales, aves...), ha dado un mejor entendimiento y aprovechamiento de las distintas energías que le han rodeado desde el principio de los tiempos hasta nuestros días.

Desde siempre la energía ha sido una necesidad básica para la vida del hombre. Tradicionalmente su producción se ha llevado a cabo haciendo uso de los combustibles fósiles que en vista de la situación actual cada vez son menos viables. En primer lugar porque las previsiones del petróleo, combustible principal hasta el día de hoy, son cada vez menores y los costes de extracción son cada vez mayores sobre todo a causa de la inestabilidad política y la presencia de conflictos armados en muchos países exportadores de esta fuente de energía. Y en segundo lugar, se culpa a los gases resultantes de la combustión de los combustibles fósiles de ser los principales causantes de una serie de cambios naturales y del clima conocidos a día de hoy como "cambio climático" que está teniendo consecuencias negativas.[4]

La referencia más antigua que se tiene es un molino de viento que fue usado para hacer funcionar un órgano en el siglo I era común. Los primeros molinos de uso práctico fueron construidos en Sistán, Afganistán, en el siglo VII. Estos fueron molinos de eje vertical con hojas rectangulares. Aparatos hechos de 6 a 8 velas de molino cubiertos con telas fueron usados para moler trigo o extraer agua.

La reducción de las reservas en la UE y EE.UU, la creciente concentración en áreas geográficas con elevada inestabilidad política y la creciente competencia por los recursos energéticos con la entrada de China e India en la escena energética hacen a las energías renovables más fuertes.

En cuanto a la vulnerabilidad de los países a los cortes energéticos, casos que se han producido con desastrosas consecuencias para la economía y la sociedad, las energías alternativas forman parte de la estrategia para no depender energéticamente del exterior, teniendo así una seguridad añadida.

Los objetivos estratégicos a nivel europeo son:

- Transformar UE en economía de alta eficiencia energética y bajas emisiones de gases de efecto invernadero

- Mediante políticas energéticas y climáticas integradas que persigan:
 - Aumentar la seguridad de abastecimiento
 - Garantizar competitividad economía y disponibilidad de energía asequible
 - Promover sostenibilidad ambiental y protección del clima

- Respetando competencias de los Estados, explotación de los recursos energéticos, selección y estructura de las fuentes de energía

Debido a lo anterior y en busca de una solución, sin mermar las necesidades energéticas, desde hace algunas décadas se han empezado a desarrollar las “energías alternativas o renovables” cada vez con más inversión y desarrollo.

La Ley 2/2011, de regulación del Sector Eléctrico Canario, 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.

1.2 Las energías renovables

Buena parte de los países del mundo así como el Gobierno de Canarias, han fijado ambiciosos objetivos en cuanto a la generación de la electricidad utilizando como fuente las energías renovables.

Producir energía limpia, apostar por las renovables, frenar la dependencia de las importaciones energéticas y limitar el efecto invernadero, son objetivos a los que es difícil oponerse. Las energías renovables podrían solucionar muchos de los problemas ambientales. Pero las energías limpias no solo presentan mejoras para el medio ambiente, sino que también ofrecen ventajas de carácter estratégico y socioeconómico con respecto a las convencionales. Las energías renovables permiten reducir las dependencias energéticas del exterior, al ser autónomas.

Desde el punto de vista socioeconómico las energías renovables contribuyen al equilibrio inter-territorial, ya que suelen instalarse en zonas rurales. Además de crear puestos de trabajo.

Los sistemas de aprovechamiento de la energía eólica para la generación de energía eléctrica (parques eólicos), son instalaciones que requieren grandes inversiones económicas, 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.

Como ha reconocido la Comisión Europea, los resultados del modelo español constituyen un ejemplo de éxito en el diseño de las políticas de promoción de las renovables. El principal resultado es el volumen alcanzado por las energías renovables eléctricas, que han consolidado una posición estructural de primer orden [16]. Durante 2009, las tecnologías renovables supusieron alrededor del 25% de la generación eléctrica total. Asimismo, las energías renovables representaron un 12,2% de la energía final bruta consumida en España [10].

En cierta manera, se puede afirmar que el Plan de Energías Renovables 2005-2010 ha constituido un éxito por el que ha transformado el modelo energético español y ha permitido el desarrollo de una industria que se ha posicionado como líder en muchos segmentos a nivel internacional.

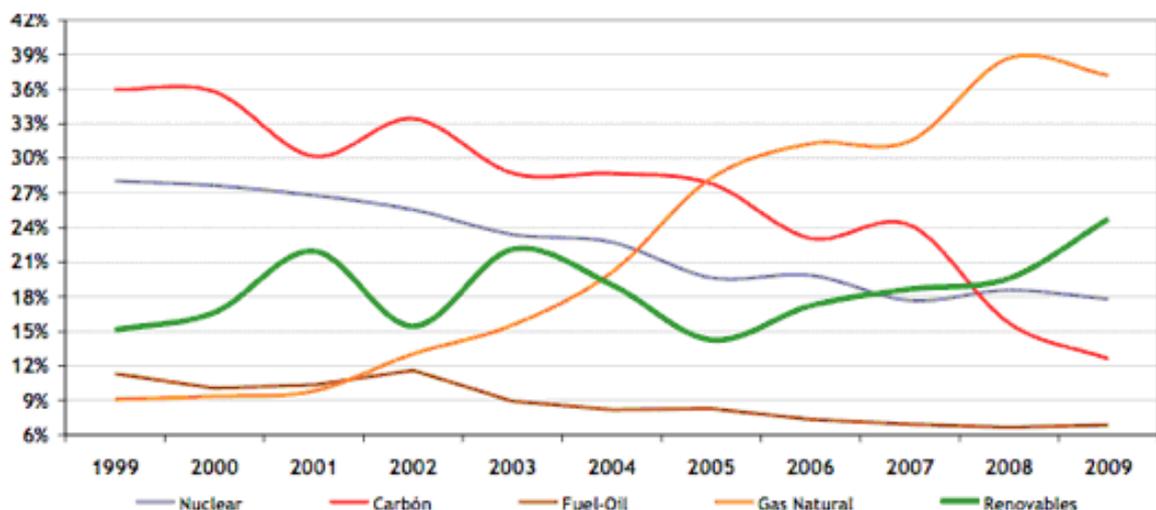


Figura 1.1: Participación de las distintas fuentes de energía en la generación eléctrica

Fuente: PANER 2011-2020

Se puede observar en la figura 1.1 que la generación eléctrica ha experimentado una importante transformación desde el 99, 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 [15].

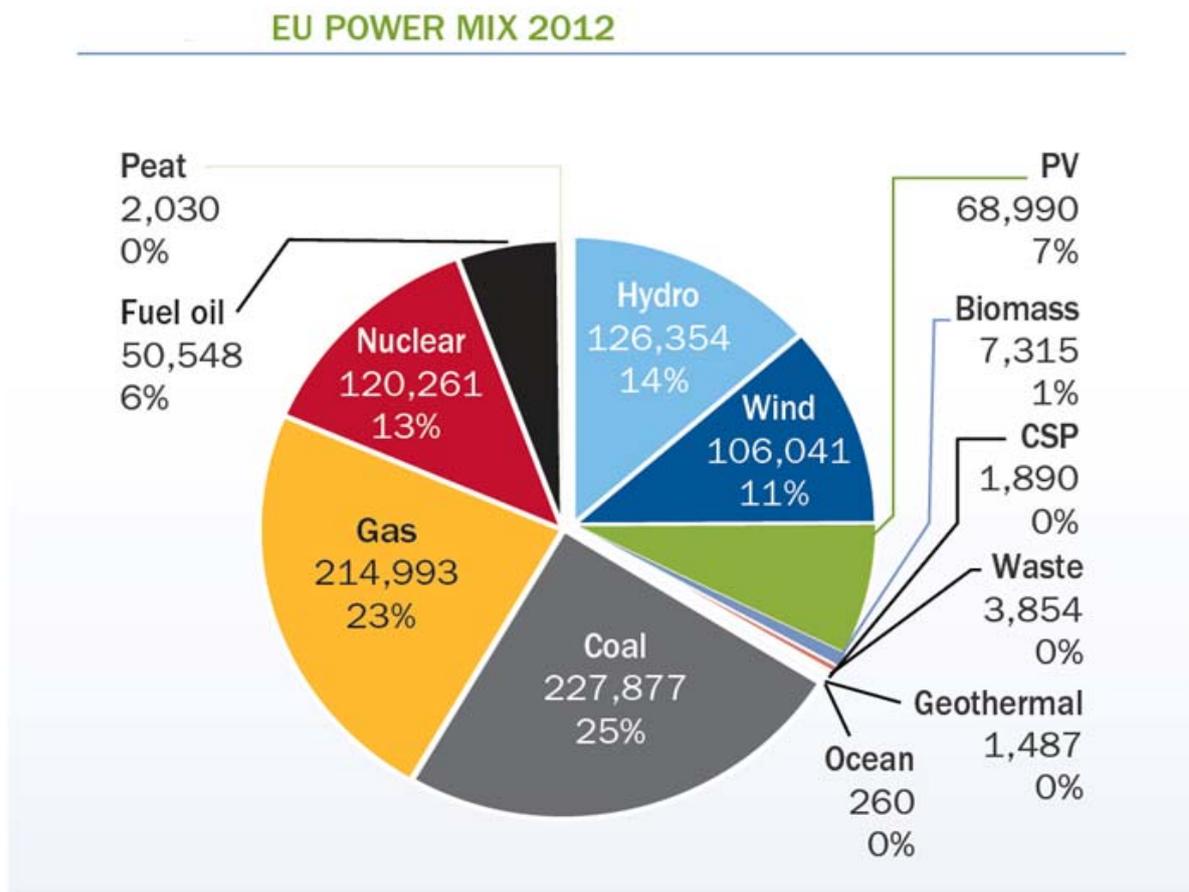


Figura 1.2: Reparto de nueva potencia eólica instalada de los países de la UE a diciembre de 2012 [1]

Fuente: EWEA

En la figura anterior se puede observar la distribución de los distintos tipos de energías renovables disponibles en la Unión Europea. De esto se desprende que la energía eólica está en un lugar destacado entre las renovables, estando casi a la par a la energía nuclear.

Esta energía limpia, no contaminante, supone el 11% y su desarrollo e instalaciones van en aumento, habiendo ayudas a tal efecto. [3]

Finalizado el período de vigencia del PER 2005-2010 [17] y atendiendo al mandato establecido en la legislación vigente procede, por lo tanto, la elaboración de un nuevo Plan, con el diseño de nuevos escenarios y la incorporación de objetivos acordes con la Directiva 2009/28/CE del Parlamento Europeo y del Consejo, de 23 de abril del 2009, relativa al fomento del uso de fuentes renovables, la cual establece los objetivos mínimos vinculantes para el conjunto de la Unión Europea y para cada uno de los Estado miembros, y la necesidad de que cada Estado miembro elabore y notifique a la Comisión Europea (CE), 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.

La Directiva establece como objetivos generales, conseguir una cuota mínima del 20% de energía procedente de fuentes renovables en el consumo final bruto de energía de la Unión Europea, el mismo objetivo establecido para España y una cuota mínima 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.

La Directiva 2009/28/CE es parte del denominado Paquete Europeo de Energía y Cambio Climático, que establece las bases para que la UE logre sus objetivos para 2020: un 20% de mejora de la eficiencia energética, una contribución de las energías renovables del 20% y una reducción de las emisiones de gases de efecto invernadero (GEI) del 20%.

España ha respondido ante esta situación redactando el PANER, y el PER 2011-2020 [15], este último elaborado por la Secretaría de Estado de Energía del Ministerio de Industria, Turismo y Comercio, a través del IDAE.

En 2020, el grado de éxito del nuevo Plan deberá medirse en atención a otros parámetros. Las estrategias a desarrollar deben representar un impulso a la investigación, desarrollo e innovación de las tecnologías renovables desarrollar nuevas tecnologías e iniciar otras nuevas que ayuden al sistema. En un futuro, las energías renovables y el gas natural abarcarán gran parte del abastecimiento nacional.

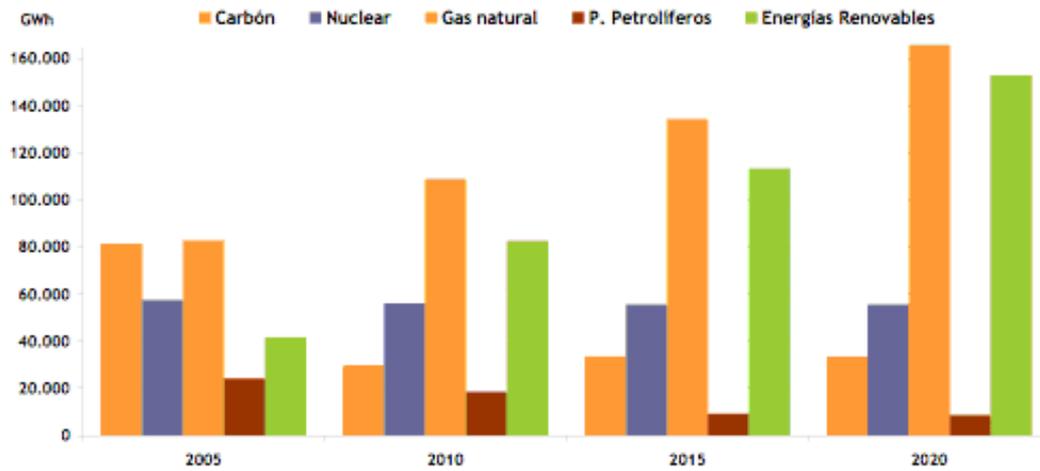


Figura 1.3: Evolución de la producción eléctrica según fuentes energéticas.

Fuente: PANER 2011-2020

Dentro de las energías renovables, se mantendrá el protagonismo de la energía eólica e hidráulica, con más del 70% de toda la producción eléctrica renovable, predominando la primera con gran iniciativa empresarial.

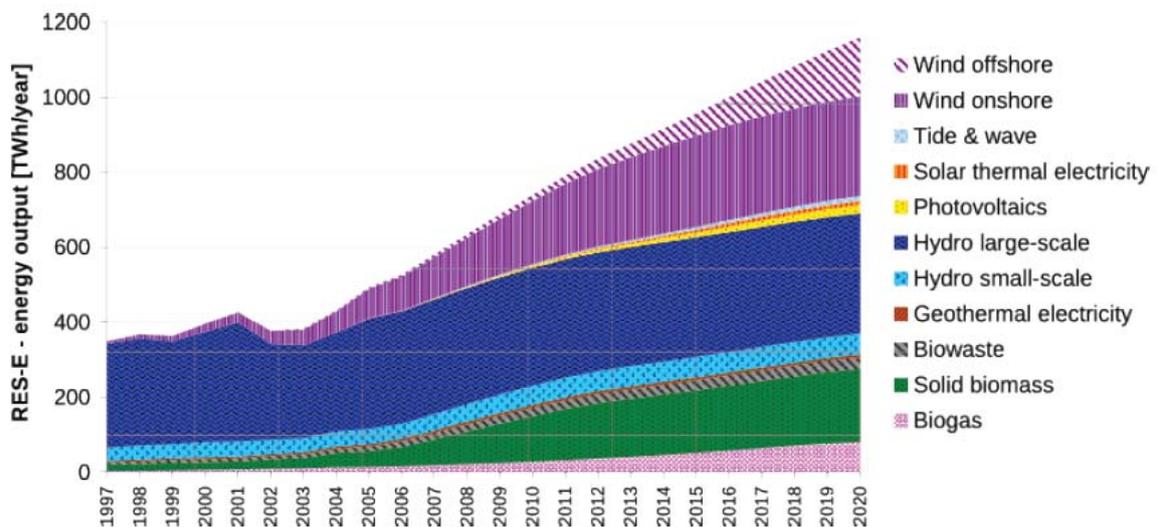


Figura 1.4: Mapa de la evolución de la energía renovable

Fuente: Comisión Europea

Como se puede observar en la figura 1.4, se pretende que en el 2020 más de 1/3 de la energía renovable producida en la UE sea eólica, con instalaciones tanto en tierra como en el mar.

Así pues, la energía eólica puede constituir una de las alternativas más atractivas para reducir las emisiones contaminantes y avanzar hacia la sostenibilidad del modelo energético.

En el siguiente gráfico puede observar la cantidad de empleo que genera la instalación, mantenimiento y desarrollo de la energía eólica en España.

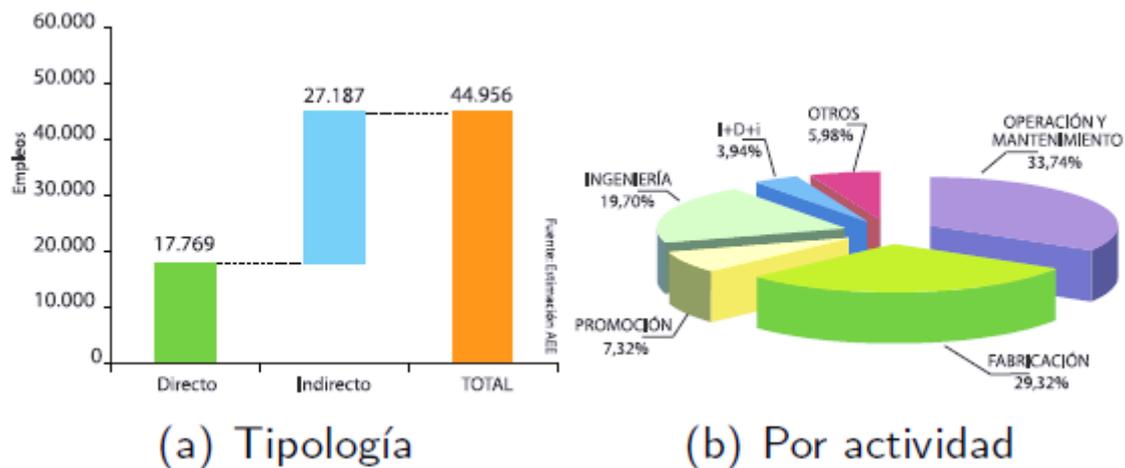


Figura 1.5: Empleo generado por la Energía Eólica a nivel nacional.

Fuente: Asociación Empresarial Eólica, EWEA

Las compañías directamente relacionadas con la energía eólica emplean a nivel europeo 108.600 trabajadores, alcanzando más de 150.000 si se tienen en cuenta los empleos indirectos.

El 77% de los empleos se localiza en Dinamarca, Alemania y España. [2]

En el caso concreto de España podemos observar en cuanto a los aspectos negativos que tiene:

- Elevada dependencia energética exterior (84% en 2008)
- Crecimiento elevado del consumo eléctrico, 70.6% entre 1996 y 2008
- Mejoras limitadas en eficiencia energética
- Elevado incremento de la actividad económica (57.8% entre 1996 y 2008)
- Incremento de emisiones de CO2 (52.6% entre 1990 y 2007)
- España tiene interconexiones eléctricas muy débiles con la Unión Europea

Aspectos positivos

- Zonas con elevado recurso de energía renovable
- Apoyo político, empresarial y ciudadano a las energías renovables

1.3 La energía eólica

En los siguientes apartados se describe la naturaleza física del fenómeno meteorológico que conocemos por viento y la evolución de su aprovechamiento por el hombre desde el principio de los tiempos hasta nuestros días.

1.3.1 El viento

La energía eólica tiene su origen, como el de la mayor parte de las fuentes energéticas del planeta, en la energía solar. El calentamiento de masas de aire como consecuencia de la radiación solar contribuye a la aparición de corrientes ascendentes, siendo el espacio que liberan ocupado por otras masas adyacentes de aire más frío. El movimiento de las masas de aire como consecuencia del calentamiento ocasiona también la aparición de diferencias de presión, que a su vez contribuyen al propio movimiento del aire en forma de fuerzas de gradiente de presión.

Los vientos son generados a causa del calentamiento no uniforme de la superficie terrestre por parte de la radiación solar, entre el 1 y 2 % de la energía proveniente del sol se convierte en viento. De día, las masas de aire sobre los océanos, los mares y los lagos se mantienen frías con relación a las áreas vecinas situadas sobre las masas continentales.

Los continentes absorben una menor cantidad de luz solar, por lo tanto el aire que se encuentra sobre la tierra se expande, y se hace por lo tanto más liviana y se eleva. El aire más frío y más pesado que proviene de los mares, océanos y grandes lagos se pone en movimiento para ocupar el lugar dejado por el aire caliente.

El movimiento del aire, o viento, a alturas por encima de 1000 m de la superficie terrestre viene condicionado, fundamentalmente, por las diferencias de presión entre las distintas

zonas y por la fuerza de Coriolis, consecuencia del giro de la Tierra. Una masa de aire inicialmente en reposo se moverá a una zona de menor presión que la que ocupa. Cuando esa masa de aire comienza su movimiento, puede ser desviada por la fuerza de Coriolis (en función de su dirección). La "desviación" del viento es proporcional a la velocidad del mismo: a mayor velocidad mayor desviación con respecto a la dirección inicial. Conforme el viento gana velocidad, la "desviación" aumenta hasta que la fuerza de Coriolis iguala a la fuerza de gradiente de presión. Llegado a esta situación el viento fluirá paralelo a las líneas isobaras. Cuando esto sucede, denominamos al viento como geostrófico. Los vientos geostróficos (también llamados globales) no vienen influenciados por la superficie terrestre, ya que aparecen a alturas superiores a los 1.000 metros.

La superficie terrestre representa una fricción para el viento que fluye sobre la misma. Esta fricción puede contribuir a cambiar la dirección del viento y disminuir su velocidad. La composición o estructura del terreno afecta directamente al valor de la fricción. Una superficie muy "rugosa", como puede ser una zona boscosa, afectará significativamente a la velocidad del viento en la superficie, reduciendo su velocidad con respecto a otras áreas adyacentes pero menos "rugosas", como puede ser la superficie de un lago.

Conforme vamos ganando altura sobre la superficie del terreno, las características superficiales (rugosidad, obstáculos) tienen cada vez menos influencia en el valor de la velocidad o dirección del viento. Cuando alcanzamos una altura para la cual la influencia de las características del terreno es nula, el viento tiene las propiedades de viento geostrófico. Esa altura es la que constituye la altura de la capa límite, que depende de factores como el tipo de terreno, el valor de la velocidad del viento, el perfil vertical de temperaturas, la hora del día, etc. Habitualmente esta capa límite se encuentra en alturas entre 1.000 y 2.000 metros.

Desde el punto de vista del aprovechamiento de la energía del viento, con las tecnologías actuales, el viento a nivel de superficie de la tierra es mucho más importante que el viento geostrófico. En este sentido, ciertas características del terreno pueden provocar la aparición de unos vientos locales que tienen una escasa dependencia con los vientos globales. Una muestra clara de esto son las zonas costeras, donde la característica local de cercanía de una gran masa de agua provoca la formación de un viento que fluye hacia el interior durante el día y hacia el mar durante la noche. Este viento, conocido como brisa, es consecuencia de las diferencias de temperatura entre las superficies del agua del mar y la tierra. Otro viento local es el que se produce en zonas montañosas, en las que el calentamiento del aire en

laderas soleadas hace que éste ascienda por las mismas por el día y descienda por las noches.

La utilización del viento, del movimiento del aire, como fuente energética implica transformar su energía cinética en otra forma de energía aprovechable por el hombre como la de transformación de la energía del viento (energía eólica) en energía eléctrica.

Realizamos primero una transformación de energía eólica a energía cinética de rotación que, actuando sobre el eje de un generador eléctrico, se transformará en energía eléctrica. La transformación de la energía eólica en energía cinética de rotación se realiza por medio de la acción del viento sobre unas palas unidas a un eje de giro (eje a su vez acoplado mecánicamente con el eje del generador eléctrico). La fuerza del viento sobre las palas produce un par de giro en el eje. La potencia mecánica transferida al eje por el viento depende de la densidad del aire, del área de barrido de las palas y de la velocidad del viento, tal como muestra la ecuación:

Ecuación (1.1)
$$P_m(t) = \frac{1}{2} \times C_p \times \rho(t) \times A \times v^3(t)$$

Donde:

$P_m(t)$, Potencia mecánica en el instante t.

A, Área de barrido de palas.

$\rho(t)$, Densidad del aire en el instante t.

$v(t)$, Velocidad del viento en el instante t.

C_p , representa el rendimiento de la máquina que realiza la conversión de energía eólica a eléctrica (aerogenerador).

El coeficiente C_p depende del tipo de máquina e incluso de las condiciones de funcionamiento, pero tiene un límite teórico, el conocido como límite de Betz. Este límite, formulado por el físico Albert Betz en 1919, está establecido en un valor de 59.3%. Para un aerogenerador moderno el valor máximo para el coeficiente de rendimiento C_p está en torno al 45%.

A continuación, en las figuras 1.5 y 1.6, se detalla el principio de funcionamiento de un aerogenerador y las distintas etapas que suceden desde que el viento llega al aerogenerador hasta que llega a los consumidores, así como las distintas partes de las que consta.

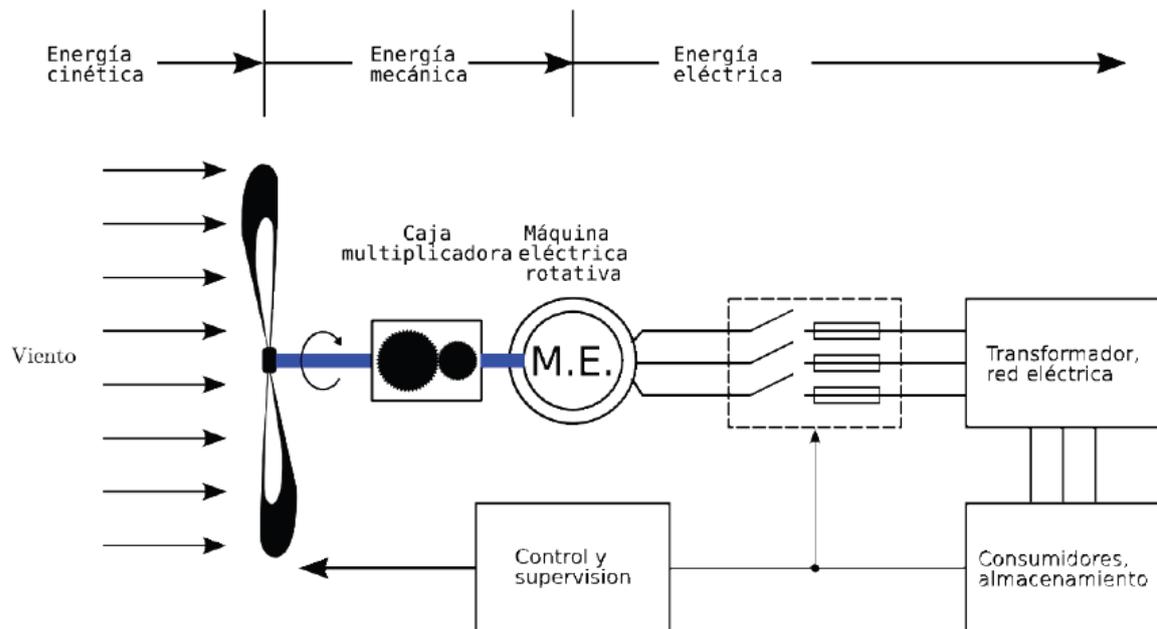


Figura 1.6: Principio de funcionamiento de un aerogenerador

Fuente: AWEA

Como podemos observar en la figura anterior, dependiendo de la velocidad del viento será la energía cinética, una vez el viento choca con las palas del aerogenerador, lo mueve y se convierte en energía mecánica y por medio del generador se convierte en energía eléctrica, que una vez transformada se traspasa a la red para su transporte por la misma hasta el usuario final debiendo de ser controlada y supervisada en todo momento.

En la imagen siguiente se observa, en forma de radiografía, como son las partes físicamente en el interior de un aerogenerador, en este caso un NORDEX N60.

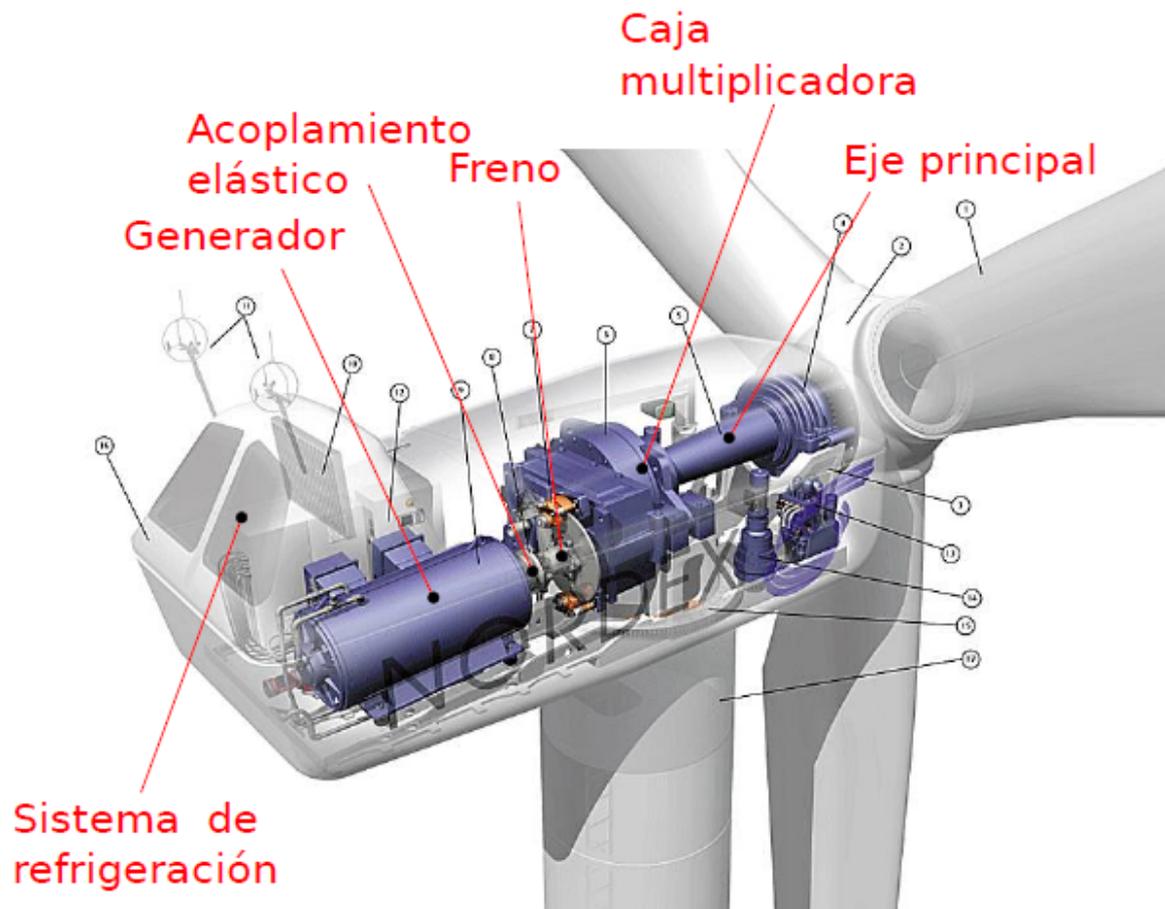


Figura 1.7: Principales componentes de un aerogenerador

Fuente: NORDEX N60

Vemos las partes, el EJE PRINCIPAL que es movido por las palas al incidir el viento en ellas, la CAJA MULTIPLICADORA que el funcionamiento es parecido a la de un vehículo cualquiera, el FRENO en caso de que la velocidad del viento sea excesiva actuará para evitar averías, ACOPLAMIENTO ELÁSTICO para unir la caja multiplicadora con el generador, el GENERADOR es el que convierte la energía cinética del viento en energía eléctrica y el SISTEMA DE REFRIGERACIÓN para enfriar las distintas partes del aerogenerador en caso de sobrecalentamiento. Todo esto acompañado de las distintas sondas para medir las temperaturas, dirección y velocidad del viento, revoluciones (rpm), etc. [8]

En la figura siguiente se puede observar la evolución de los aerogeneradores desde el año 1985 hasta los actuales. Al principio eran del orden de KW y ahora están en MW con un diámetro de 160m.



Figura 1.8: Evolución del tamaño de aerogeneradores

Fuente: AEE

El gráfico anterior nos lleva al siguiente y se observa como las energías renovables, entre ellas la energía eólica, aumenta y se prevé que siga así en los próximos años.

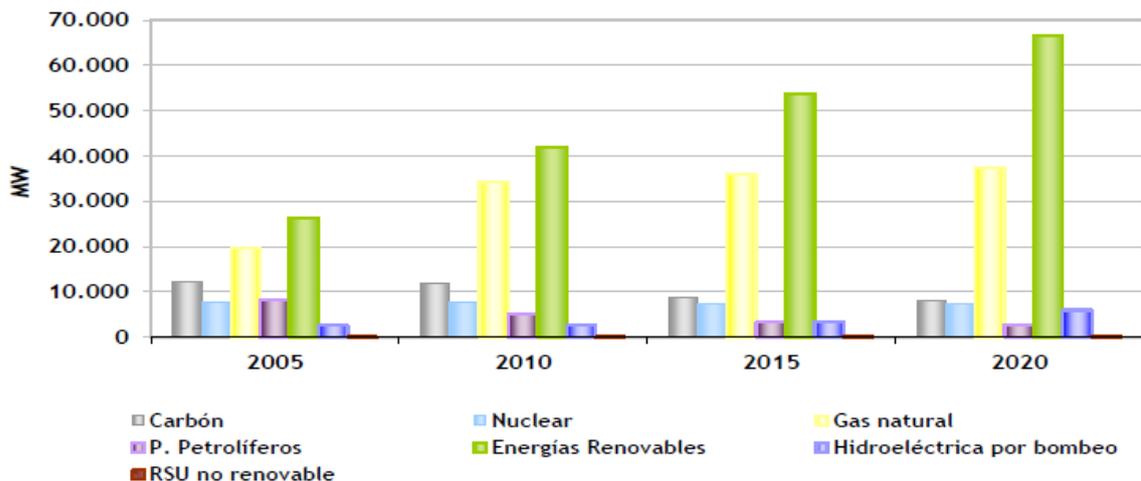


Figura 1.9: Escenario de la eficiencia energética adicional: Evolución de la capacidad eléctrica instalada según fuentes energéticas.

Fuente: MITyC / IDAE

1.4 MARCO NORMATIVO

El sector eólico es un sector regulado, por lo que el marco normativo es fundamental para su evolución. El marco que regula del sector incluye, como pilar fundamental, la Ley del Sector Eléctrico de 1997, modificada por la Ley 2/2011 y su normativa de desarrollo.

Entre esta normativa de desarrollo destacan especialmente, el Real Decreto 661/2007 que establece los actuales niveles de retribución del sector así como el Real Decreto-Ley 6/2009 introdujo la figura del Registro de Preasignación. El Real Decreto 661/2007, por otra parte, ha sido recientemente modificado por los Reales Decretos 1614/2010 y 1565/2010. Más allá, la normativa nacional debe incorporar la Directiva 2009/28/EC sobre el fomento del uso de las energías de fuente renovable así como la Directiva 2009/72/EC sobre normas comunes para el mercado interior de la electricidad y otras disposiciones vinculantes de la Unión Europea.

NORMATIVA NACIONAL:

- Orden ITC/3353/2010, de 28 de diciembre, por la que se establecen los peajes de acceso a partir de 1 de enero de 2011 y las tarifas y primas de las instalaciones del régimen especial.

- Real Decreto 1614/2010, de 7 de diciembre, por el que se regulan y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica a partir de tecnologías solar termoeléctrica y eólica.

- Corrección de errores del Real Decreto 1565/2010, de 19 de noviembre, por el que se regula y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica en régimen especial.

- Real Decreto 661/2007, de 25 de mayo, por el que se regula la actividad de producción de energía eléctrica en régimen especial.

- Corrección de errores del Real Decreto 661/2007, de 25 de mayo, por el que se regula la actividad de producción de energía eléctrica en régimen especial. BOE 26/7/07.

- Real Decreto-ley 6/2009, de 30 de abril, por el que se adoptan determinadas medidas en el sector energético y se aprueba el bono social

- Real Decreto 1565/2010, de 19 de noviembre, por el que se regulan y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica en régimen especial.

- Real Decreto 198/2010, de 26 de febrero, por el que se adaptan determinadas disposiciones relativas al sector eléctrico a lo dispuesto en la Ley 25/2009, de modificación de diversas leyes para su adaptación a la ley sobre el libre acceso a las actividades de servicios y su ejercicio.

- Real Decreto 1028/2007, de 20 de julio, por el que se establece el procedimiento administrativo para la tramitación de las solicitudes de autorización de instalaciones de generación eléctrica en el mar territorial.

NORMATIVA AUTONÓMICA:

- DECRETO 121/2011, de 17 de mayo, que modifica parcialmente el Decreto 32/2006.

- DECRETO 7/2011, de 20 de enero, que modifica el 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.

- 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. (BOCA Nº 61/2006).

- DECRETO 141/2009, de 10 de noviembre, por el que se aprueba el Reglamento por el que se regulan los procedimientos administrativos relativos a la ejecución y puesta en servicio de las instalaciones eléctricas en Canarias.

- RESOLUCIÓN de 4 de octubre de 2006, de la Secretaría General de Energía, por la que se aprueba el procedimiento de operación 12.3 Requisitos de respuesta frente a huecos de tensión de las instalaciones eólicas.

- Orden de 15 de Noviembre de 2006, por la que se regulan las condiciones Técnico-Administrativas de las instalaciones eólicas ubicadas en Canarias. (BOCA Nº 225/2006).

- Ley 2/2011, de 26 de enero, por la que se modifican la Ley 11/1997, de 2 de diciembre, de regulación del Sector Eléctrico Canario y la Ley 19/2003, de 14 de abril, por la que se aprueban las Directrices de Ordenación General y las Directrices de Ordenación del Turismo de Canarias.

1.5 REFERENCIAS:

- [1]: Aeeolica. Estudio sobre la eólica en el mundo. <http://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-el-mundo/>. 2015.
- [2]: Acciona. Líneas de negocio estudiadas por la empresa Acciona. <http://www.acciona.es/lineas-de-negocio/energia?gclid=CMLTm8a5n7gCFdDMtAodaSYAJQ>. 2014.
- [3]: Acciona. Áreas de la actividad de la energía eólica por la empresa Acciona. http://www.acciona-energia.es/areas_actividad/eolica.aspx. 2014.
- [4]: Ayuntamiento de Pamplona. Aprovechamiento de la energía eólica en la región de Pamplona dada por sus instituciones públicas. <http://www.pamplona.es>. 2014.
- [5]: EWEA (European Wind Energy Association). <http://www.ewea.org>. 2014.
- WIND ENERGY THE FACTS
 - PRIORITISING WIND ENERGY RESEARCH
- [6]: ASOCIACIÓN DANESA DE ENERGÍA EÓLICA. Wind Industry annual. <http://www.windpower.org>. 2015.
- [7]: Renewable Energy Magazine. ENERGIAS RENOVABLES / BOLETÍN EÓLICO www.energias-renovables.com. 2015.
- [8]: NORDEX. Nordex N60. http://www.nordex-online.com/fileadmin/MEDIA/Produktinfos/EN/Nordex_N60_EN.pdf. 2015.
- [9]: COMISION NACIONAL DE LA ENERGÍA. Centro de comunicación de energía. www.cne.es. 2015.
- [10]: RED ELECTRICA ESPAÑOLA. Informe del sistema eléctrico español. <http://www.ree.es/es/publicaciones/sistema-electrico-espanol/informe-anual/informe-del-sistema-electrico-espanol-2014>. 2014.
- [11]: ASOCIACIÓN DE PROMOTORES EERR (APPA). Energía primaria y producción eléctrica. <http://www.appa.es/01energias/01espana.php>. 2014.
- [12]: ASOCIACIÓN EMPRESARIAL EÓLICA. La eólica en España. <http://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-espana/>. 2015.
- [13]: INSTITUTO PARA LA DIVERSIFICACIÓN Y AHORRO DE LA ENERGÍA. Publicaciones. www.idae.es/publicaciones. 2015.
- [14]: Ministerio de Economía y competitividad. CENTRO DE INVESTIGACIONES ENERGÉTICAS, MEDIOAMBIENTALES Y TECNOLÓGICAS. <http://www.ciemat.es/portal.do?IDM=212&NM=2>. 2014.
- [15]: Ministerio de Industria, Energía y Turismo. Plan de Energías Renovables (PER). http://www.minetur.gob.es/energia/es-ES/Novedades/Documents/Resumen_PER_2011-2020.pdf. 2015.

[16]: Ministerio de Industria, Energía y Turismo. Plan de Acción Nacional de Energías Renovables de España (PANER) 2011 – 2020. http://www.minetur.gob.es/energia/es-ES/Novedades/Documents/Resumen_PER_2011-2020.pdf. 2015.

[17]: Ministerio de Industria, Energía y Turismo. Plan de Energías Renovables 2011-20 (PER 2011-2020) elaborado por la Secretaría de Estado de Energía del Ministerio de Industria, Turismo y Comercio, a través del IDAE. <http://idae.electura.es/libros/504/>. 2014.

CAPÍTULO 2

Aprovechamiento del Recurso Eólico

INDICE

2.1 Evolución del aprovechamiento de la energía eólica.....	23
2.1.1 A nivel mundial.....	30
2.1.2 En Europa.....	34
2.1.3 A nivel nacional.....	38
2.1.4 A nivel de la Región de Canarias.....	44
2.2 Referencias.....	52

INDICE DE FIGURAS:

Figura 2.1: Aprovechamiento de la Energía Eólica

Figura 2.2: Reparto por promotores de la potencia instalada a finales de 2012

Figura 2.3: Potencia instalada por los fabricantes a finales de 2012

Figura 2.4: Capacidad instalada a nivel mundial

Figura 2.5: Capacidad instalada a nivel mundial

Figura 2.6: Contribución continental en la capacidad total instalada [%]

Figura 2.7: Evolución y pronóstico de la capacidad total instalada

Figura 2.8: Capacidad instalada en Europa (GW)

Figura 2.9: Mapa eólico de Europa

Figura 2.10: Capacidad instalada en algunos países de Europa en 2010

Figura 2.11: Evolución anual de la potencia eólica acumulada en España (1998-2012)

Figura 2.12: Evolución de la potencia eólica instalada por Comunidades Autónomas (2004-2012)

Figura 2.13: Comparación entre la potencia eólica instalada y prevista para 2020 en España

Figura 2.14: Potencia eólica instalada en Canarias

Figura 2.15: Mapa de instalaciones eólicas en Canarias

Figura 2.16: Evolución de la potencia eólica instalada en Canarias

Figura 2.17: Comparativa de potencia eólica instalada

Figura 2.18. Comparación entre la potencia eólica instalada y prevista para 2015 en Canarias

ÍNDICE DE TABLAS:

Tabla 2.1: Potencia eólica instalada en los distintos países (MW)

Tabla 2.2: Potencia eólica instalada por Comunidades Autónomas 2012

Tabla 2.3: Comparativa de la potencia eólica instalada (2005-2010) y nueva previsión de potencia (2011-2015), con la previsión PECAN (2005-2015). CANARIAS

Tabla 2.4: Potencia instalada en Canarias en el año 2015

2.1 Evolución del aprovechamiento de la energía eólica

El aprovechamiento del viento para generar energía es casi tan antiguo como la civilización. La primera y más sencilla aplicación fue la de las velas para la navegación.

El progreso humano, tanto económico como tecnológico, ha estado desde el primer momento condicionado por la existencia de unos recursos energéticos suficientes para satisfacer las necesidades que el propio progreso plantea. El viento representó, desde los mismos albores de la historia, una fuente de energía fácilmente aprovechable, fundamentalmente como sistema de propulsión en barcos. Fue precisamente este aprovechamiento de la energía eólica, la principal clave en el desarrollo del comercio y en la expansión de los grandes imperios de la antigüedad.

La referencia más antigua que se tiene es un molino de viento que fue usado para hacer funcionar un órgano en el siglo I era común. Los primeros molinos de uso práctico fueron construidos en Sistán, Afganistán, en el siglo VII. Estos fueron molinos de eje vertical con hojas rectangulares. Aparatos hechos de 6 a 8 velas de molino cubiertos con telas fueron usados para moler trigo o extraer agua [13].

Las primeras aplicaciones de energía eólica en Europa, aparte de la navegación a vela, se demoraron hasta la edad media donde se transfirió la tecnología que permitió su implantación en el viejo continente. Ya para finales del siglo XIII los molinos de viento europeos (los de La Mancha en España, o los holandeses) presentaban un aspecto similar al que mantuvieron hasta bien entrado el siglo XVIII, y con un uso exclusivo en molienda e irrigación.

Para poder aprovechar la energía eólica es importante conocer las variaciones diurnas y nocturnas y estacionales de los vientos, la variación de la velocidad del viento con la altura sobre el suelo, la entidad de las ráfagas en espacios de tiempo breves, y valores máximos ocurridos en series históricas de datos con una duración mínima de 20 años. Es también importante conocer la velocidad máxima del viento. Para poder utilizar la energía del viento, es necesario que este alcance una velocidad mínima que depende del aerogenerador que se vaya a utilizar pero que suele empezar entre los 3 m/s (10 km/h) y los 4 m/s (14,4 km/h), velocidad llamada "**cut-in speed**", y que no supere los 25 m/s (90 km/h), velocidad llamada "**cut-out speed**" [1].

Capítulo2: Aprovechamiento del recurso Eólico

La energía del viento es utilizada mediante el uso de máquinas eólicas (o aeromotores) capaces de transformar la energía eólica en energía mecánica de rotación utilizable, ya sea para accionar directamente las máquinas operatrices, como para la producción de energía eléctrica. En este último caso, el sistema de conversión, (que comprende un generador eléctrico con sus sistemas de control y de conexión a la red) es conocido como aerogenerador.

En la actualidad se utiliza, sobre todo, para mover aerogeneradores. En estos la energía eólica mueve una hélice y mediante un sistema mecánico se hace girar el rotor de un generador, normalmente un alternador, que produce energía eléctrica. Para que su instalación resulte rentable, suelen agruparse en concentraciones denominadas parques eólicos.

Un molino es una máquina que transforma el viento en energía aprovechable, que proviene de la acción de la fuerza del viento sobre unas aspas oblicuas unidas a un eje común. El eje giratorio puede conectarse a varios tipos de maquinaria para moler grano, bombear agua o generar electricidad. Cuando el eje se conecta a una carga, como una bomba, recibe el nombre de molino de viento. Si se usa para producir electricidad se le denomina generador de turbina de viento. Los molinos tienen un origen remoto. [11]

La década de los 80 del pasado siglo significó para la industria eólica el despegue definitivo, con un importante abaratamiento de los costes, consecuencia del uso de nuevos materiales y nuevas técnicas de fabricación. Este abaratamiento de costes permite que la energía eólica sea competitiva frente a otras tecnologías energéticas. La construcción de grandes parques eólicos con aerogeneradores de 55 kW es una realidad a principios de la década: en Palm Springs, California, se construye un parque con 1.000 aerogeneradores Micon de 55 kW. A partir de entonces parques eólicos con decenas o centenares de aerogeneradores se construyen por todo el mundo. Con el desarrollo de máquinas cada vez más potentes (ya existen prototipos de hasta 5 MW), la potencia media de los nuevos parques eólicos es de decenas o centenares de MW.

En los últimos 30 años el mercado de energía eólica ha estado en continua expansión, siendo los últimos 15 años el mayor desarrollo tecnológico (I+D+I).

La energía eólica no es algo nuevo, es una de las energías más antiguas junto a la energía térmica. El viento como fuerza motriz existe desde la antigüedad y en todos los tiempos ha sido utilizado como tal, como podemos observar. Tiene su origen en el sol. Así,

ha movido a barcos impulsados por velas o ha hecho funcionar la maquinaria de los molinos al mover sus aspas. Pero, fue a partir de los ochenta del siglo pasado, cuando este tipo de energía limpia sufrió un verdadero impulso [14]. La energía eólica crece de forma imparable a partir del siglo XXI, en algunos países más que en otros, pero sin duda alguna en España existe un gran crecimiento, siendo uno de los primeros países por debajo de Alemania a nivel europeo o de Estados Unidos a escala mundial. Su auge en parques eólicos es debido a las condiciones tan favorables que existe de viento, sobre todo en Andalucía que ocupa un puesto principal, entre los que se puede destacar el Golfo de Cádiz, ya que el recurso de viento es excepcional.[10]

La industria de la energía eólica en tiempos modernos comenzó en 1979 con la producción en serie de turbinas de viento por los fabricantes Kuriant, Vestas, Nordtank, y Bonus. Aquellas turbinas eran pequeñas para los estándares actuales, con capacidades de 20 a 30 kW cada una. Desde entonces, la talla de las turbinas ha crecido enormemente, y la producción se ha expandido a muchos sitios.

En el esquema que se expone a continuación se detalla como se aprovecha la energía eólica de dos formas: con aerobombas se utiliza para la extracción del agua de los pozos mediante la utilización de unos molinos a través de la energía mecánica, sin más ayuda que la del viento. El mas generalizado es el multipala de tipo americano, y de otra forma con instalaciones eólicas que llevan unidas un generador eléctrico y producen corriente cuando incide le viento en las palas y las hace girar. Este tipo de generación eléctrica puede ser aislada ó con conexión directa a la red de distribución convencional. [3]

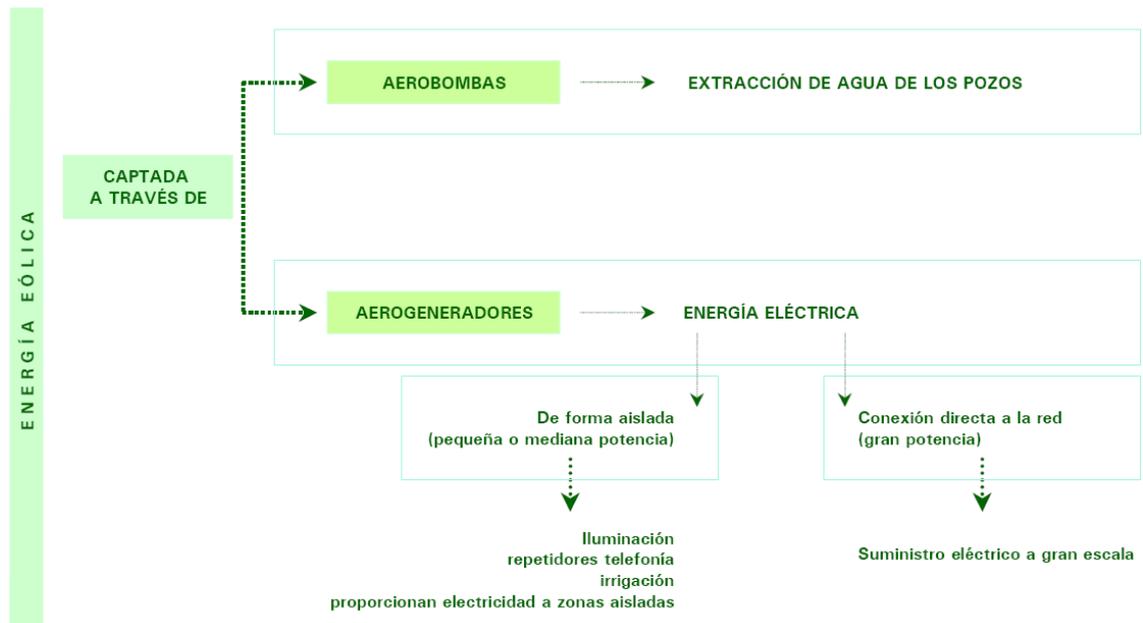


Figura 2.1: Aprovechamiento de la Energía Eólica

Fuente: Analistas de Económicos de Andalucía

En los sistemas conectados a la red la energía eléctrica producida por las turbinas es vendida a la compañía suministradora. De este modo, existen dos contadores: uno para la electricidad vendida y otro para la electricidad consumida.

Siempre que sea posible, es aconsejable conectar a red la instalación, ya que el coste de la misma es menor, y existe una prima por la venta a la red eléctrica de esta electricidad de origen renovable.

En los sistemas aislados se utilizan para proporcionar electricidad directamente a los usuarios. Generalmente, este tipo de sistemas los utilizan usuarios con consumos de energía muy bajos, para los cuales no compensa pagar el coste de la conexión a la red debido a una posición poco accesible.

La energía es acumulada en una serie de baterías, dimensionadas de forma que garanticen una suficiente autonomía para los periodos en los que el sistema eólico no produzca electricidad. En este tipo de sistemas es necesario instalar un regulador de carga.

[4]

Las instalaciones eólicas de pequeño tamaño tienen un impacto visual y medioambiental prácticamente nulo, con un tamaño poco superior al de una antena parabólica. Además de poder utilizarse de forma aislada también pueden instalarse junto a paneles fotovoltaicos y otras fuentes de energías alternativas.

Otro aspecto importante es el lugar donde instalar la turbina, ésta debe elegirse con atención. La cercanía a los usuarios tiene la ventaja de reducir los costes de cableado, pero puede ser contraproducente para la funcionalidad de la máquina por la interferencia con el viento debida a la proximidad de edificios y por el impacto del ruido. La lejanía reduce el impacto medioambiental. Pero aumenta la dispersión de energía y los costes de cableado y de enterramiento de las líneas eléctricas.

La colocación de aerogeneradores en los tejados de las casas es controvertida: por una parte el montaje es sencillo, por otra existen problemas de vibraciones transmitidas por la turbina a las estructuras sobre las que se monta, y los de turbulencia que se va creando alrededor de los tejados.

La instalación más común sigue siendo la torre, que puede ser de celosía, tubular o arriostrada.

Por otro lado, el rendimiento de las máquinas eólicas depende de la intensidad del viento: a igualdad de diámetro de las palas, al aumentar la velocidad del viento, la potencia teóricamente extraíble aumenta de manera más que proporcional.

Por lo tanto, antes de decidir instalar un sistema eólico es indispensable conocer bien las características del viento en el lugar en el que se piensa instalar los aerogeneradores. Estos conocimientos se obtienen realizando preventivamente un atento estudio de la frecuencia, de la velocidad, de la duración y de la dirección del viento.

Las máquinas eólicas funcionan dentro de parámetros mínimos y máximos de la velocidad del viento. En línea general:

- Pueden ser activados con viento variable de 2,4 m/s
- Cuando el viento alcanza la velocidad de 10-14 m/s, se activa un dispositivo de control de la potencia.

- Se paran cuando la velocidad del viento supera los 20-25m/s.

Una de las características en la medida de la eficacia de un aerogenerador son las "horas equivalentes" que determinan la cantidad de viento en la zona.

$$\text{Ecuación: 2.1 } \textit{Horas Equivalentes} = \frac{\textit{Energía real producida}}{\textit{Potencia Nominal de la Instalación eólica}} \left(\frac{\textit{MWh}}{\textit{MW}} \right)$$

Las horas equivalentes suponen la cantidad de horas que, en un año determinado, está la instalación funcionando a pleno rendimiento. (Se puede obtener midiendo la producción anual de un aerogenerador y dividiendo esa cantidad por la potencia nominal).

En cuanto al mantenimiento, se puede contratar a empresas especializadas con costes razonables, además la gestión se puede incluso realizar a distancia, a través de sistemas de mando y telecontrol que permiten, mediante un ordenador, recibir datos enviar órdenes a la instalación.

Dentro de las tareas de mantenimiento se deberá distinguir entre en mantenimiento preventivo o planificado, el cual se realiza en intervalos determinados por el fabricante y la experiencia del usuario, y el mantenimiento correctivo o no planeado.

En cuanto a las empresas que actúan en el mercado de la energía eólica, podemos, ver de forma gráfica, las que más aportan a este mercado de la energía limpia, además de aquellos fabricantes que más han aportado al desarrollo, instalaciones y venta de aerogeneradores.

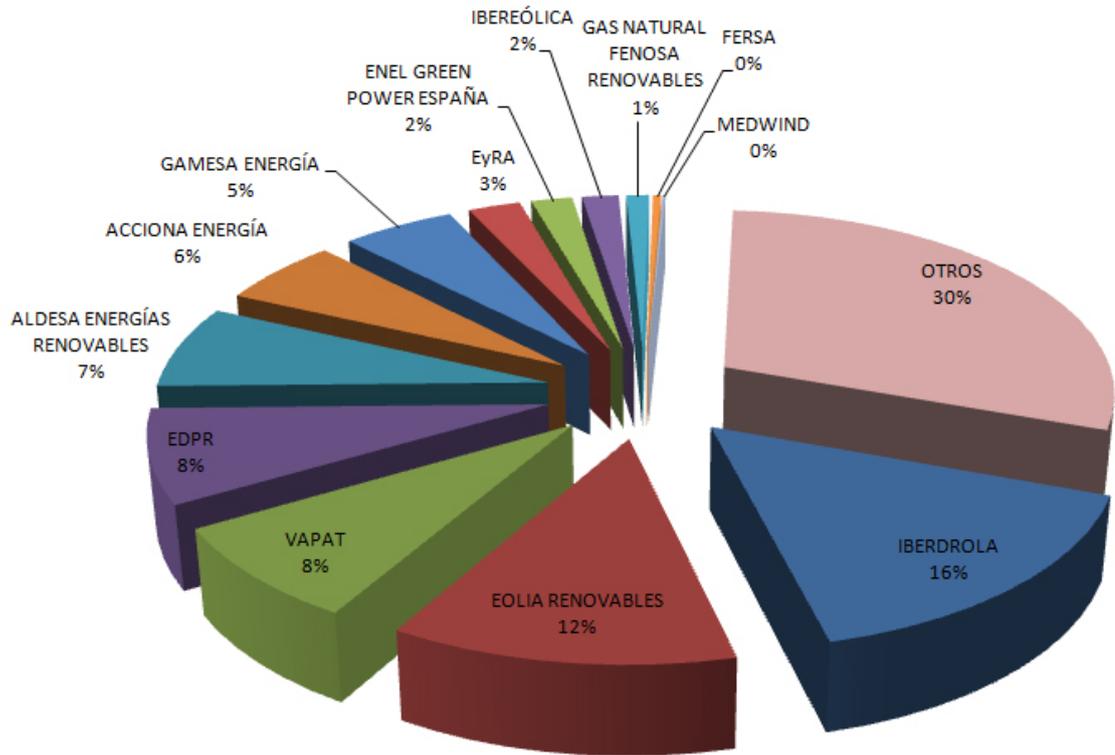


Figura: 2.2: Reparto por promotores de la potencia instalada a finales de 2012

Fuente: AEE

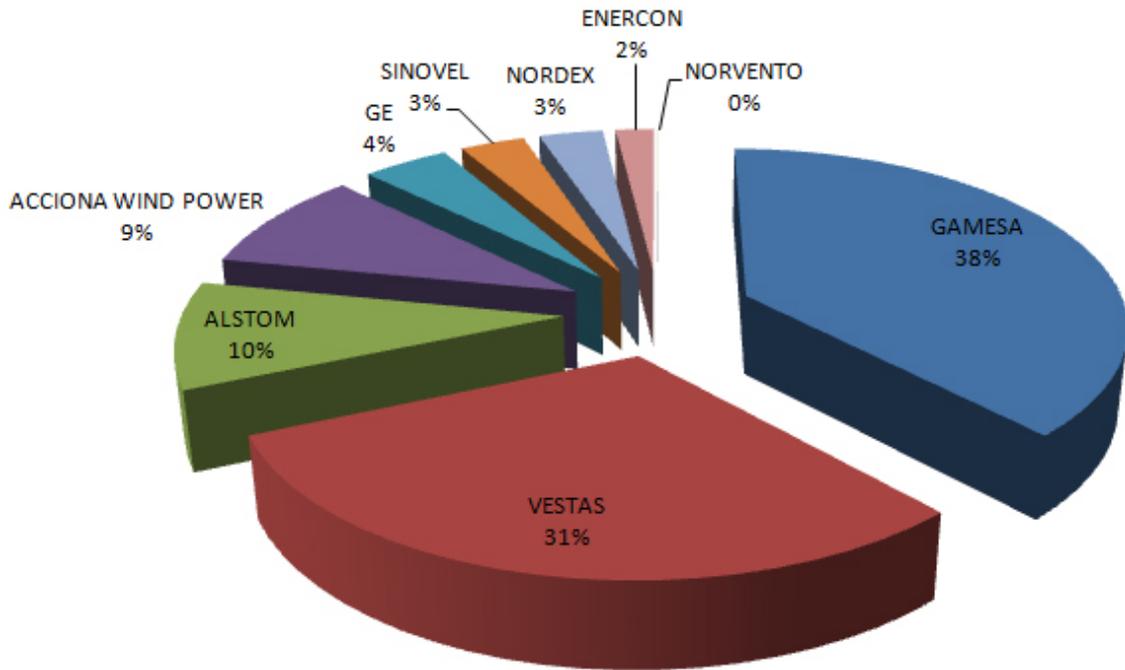


Figura: 2.3: Potencia instalada por los fabricantes a finales de 2012

Fuente: AEE

2.1.1 A nivel Mundial

En Estados Unidos, el desarrollo de molinos de bombeo, reconocibles por sus múltiples velas metálicas, fue el factor principal que permitió la agricultura y la ganadería en vastas áreas de Norteamérica, de otra manera imposible sin acceso fácil al agua. Estos molinos contribuyeron a la expansión del ferrocarril alrededor del mundo, supliendo las necesidades de agua de las locomotoras a vapor.

SITUACION ACTUAL:

Según un informe de Global Wind Energy Council [5], la capacidad instalada a nivel mundial en el año 2012 de energía eólica llegó a los 282.430 Megavatios, luego de 238.035 MW en 2011, 197.686 MW en 2010, y 158.864 MW en 2009, La energía eólica instalada en el mundo creció alrededor de un 10% en 2012, hasta situarse en 282.430 MW, según datos del Global Wind Energy Council (GWEC). China, Estados Unidos, Alemania y España son los primeros productores mundiales.

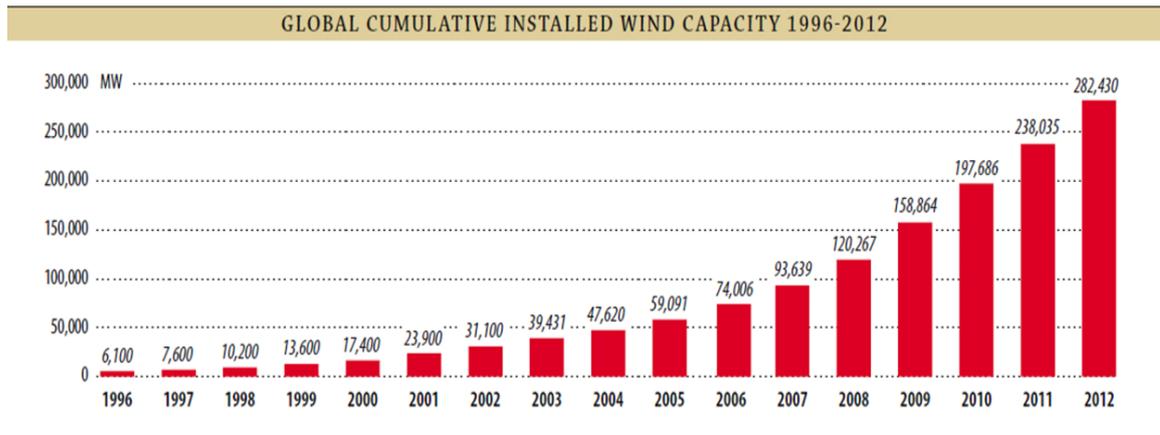


Figura 2.4: Capacidad instalada a nivel mundial

Fuente: GWEC y AEE



Figura 2.5: Capacidad instalada a nivel mundial

Fuente: GWEC

En el gráfico anterior se muestra que Europa sigue representando la región del mundo con la mayor capacidad eólica instalada, muchas de ellas con parques de más de 1GW y siendo la pionera en parques Offshore.

Con una participación del 43,7 % en la capacidad mundial.

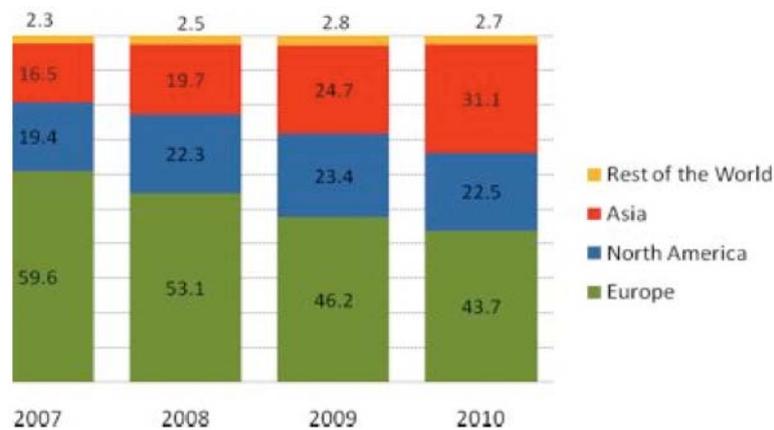


Figura 2.6: Contribución continental en la capacidad total instalada [%].

Fuente: WWEA

China se convirtió en el país con mayor capacidad instalada a nivel mundial y el centro de la industria eólica a nivel internacional. Añadió 16.500 Megavatios durante el año, contabilizando más del 50 % de la capacidad instalada a nivel mundial durante el 2010.

En la tabla 2.1 se puede observar un listado de los 15 países del mundo con mayor potencia instalada. Cabe destacar que España se encuentra el cuarto lugar, tras Estados Unidos, Alemania y China.

Tabla 2.1: Potencia eólica instalada en los distintos países (MW).

Fuente: WWEA

Position 2012	Country/Region	Total capacity installed end 2012 [MW]	Added capacity 2012 [MW]	Growth rate 2012 [%]	Position 2011	Total capacity installed end 2011 [MW]	Total capacity installed end 2010 [MW]	Total capacity installed end 2009 [MW]	Total Capacity installed end 2008 [MW]
1	China	75'324,0	12'960,0	20,8	1	62'364,0	44'733,0	25'810,0	12'210,0
2	USA	59'882,0	12'999,0	27,6	2	46'919,0	40'180,0	35'159,0	25'237,0
3	Germany	31'308,0	2'415,0	7,7	3	29'075,0	27'215,0	25'777,0	23'897,0
4	Spain	22'796,0	1'122,0	5,2	4	21'673,0	20'676,0	19'149,0	16'689,0
5	India	18'321,0	2'441,0	15,4	5	15'880,0	13'065,8	11'807,0	9'587,0
6	United Kingdom	8'445,0	1'897,0	40,3	8	6'018,0	5'203,8	4'092,0	3'195,0
7	Italy	8'144,0	1'273,0	20,9	6	6'737,0	5'797,0	4'850,0	3'736,0
8	France	7'473,4	757,0	14,1	7	6'549,4	5'569,4	4'483,4	3'313,7
9	Canada	6'201,0	936,0	17,8	9	5'265,0	4'008,0	3'319,0	2'369,0
10	Portugal	4'525,0	145,0	10,8	10	4'083,0	3'702,0	3'357,0	2'862,0
11	Denmark	4'162,0	217,0	6,0	11	3'927,0	3'734,0	3'465,0	3'163,0
12	Sweden	3'745,0	846,0	33,8	12	2'798,0	2'052,0	1'448,2	1'066,9
13	Japan	2'614,0	87,0	4,5	13	2'501,0	2'304,0	2'083,0	1'880,0
14	Australia	2'584,0	358,0	16,1	16	2'226,0	1'880,0	1'877,0	1'494,0
15	Brazil	2'507,0	1'076,5	75,4	20	1'429,0	930,0	600,0	338,5

PERSPECTIVAS FUTURAS:

- Se espera un crecimiento notable sobre todo en China, India, Europa y América del Norte.
- Se esperan altas tasas de crecimiento en varios países de América Latina, así como nuevos mercados en Europa del este y Asia. En un mediano plazo, se proyectan grandes inversiones en algunos de los países africanos, no solo en el norte de África, sino también en el sur de África.
- Con base en las tasas de crecimiento actuales, WWEA revisa sus expectativas para el crecimiento a futuro de la capacidad eólica mundial.

En 2015, es posible llegar a una capacidad global de 600.000 MW. A finales del año 2020, por lo menos 1.500.000 MW pueden ser instalados a nivel mundial.



Figura 2.7: Evolución y pronóstico de la capacidad total instalada.

Fuente: WWEA

2.1.2 En Europa

En Europa los primeros molinos aparecieron en el siglo XII en Francia e Inglaterra y se distribuyeron por el continente. Eran unas estructuras de madera, conocidas como torres de molino, que se hacían girar a mano alrededor de un poste central para levantar sus aspas al viento. El molino de torre se desarrolló en Francia a lo largo del siglo XIV. Consistía en una torre de piedra coronada por una estructura rotativa de madera que soportaba el eje del molino y la maquinaria superior del mismo. Estos primeros ejemplares tenían una serie de características comunes. De la parte superior del molino sobresalía un eje horizontal. De este eje partían de cuatro a ocho aspas, con una longitud entre 3 y 9 metros. Las vigas de madera se cubrían con telas o planchas de madera. La energía generada por el giro del eje se transmitía, a través de un sistema de engranajes, a la maquinaria del molino emplazada en la base de la estructura. Los molinos de eje horizontal fueron usados extensamente en Europa Occidental para moler trigo desde la década de 1180 en adelante. Basta recordar los ya famosos molinos de viento en las andanzas de Don Quijote. Todavía existen molinos de esa clase, por ejemplo, en Holanda

SITUACION ACTUAL:

Europa sigue representando la región del mundo con la mayor capacidad eólica instalada con un total de 106 GW en 2012 y sigue en aumento. [2]

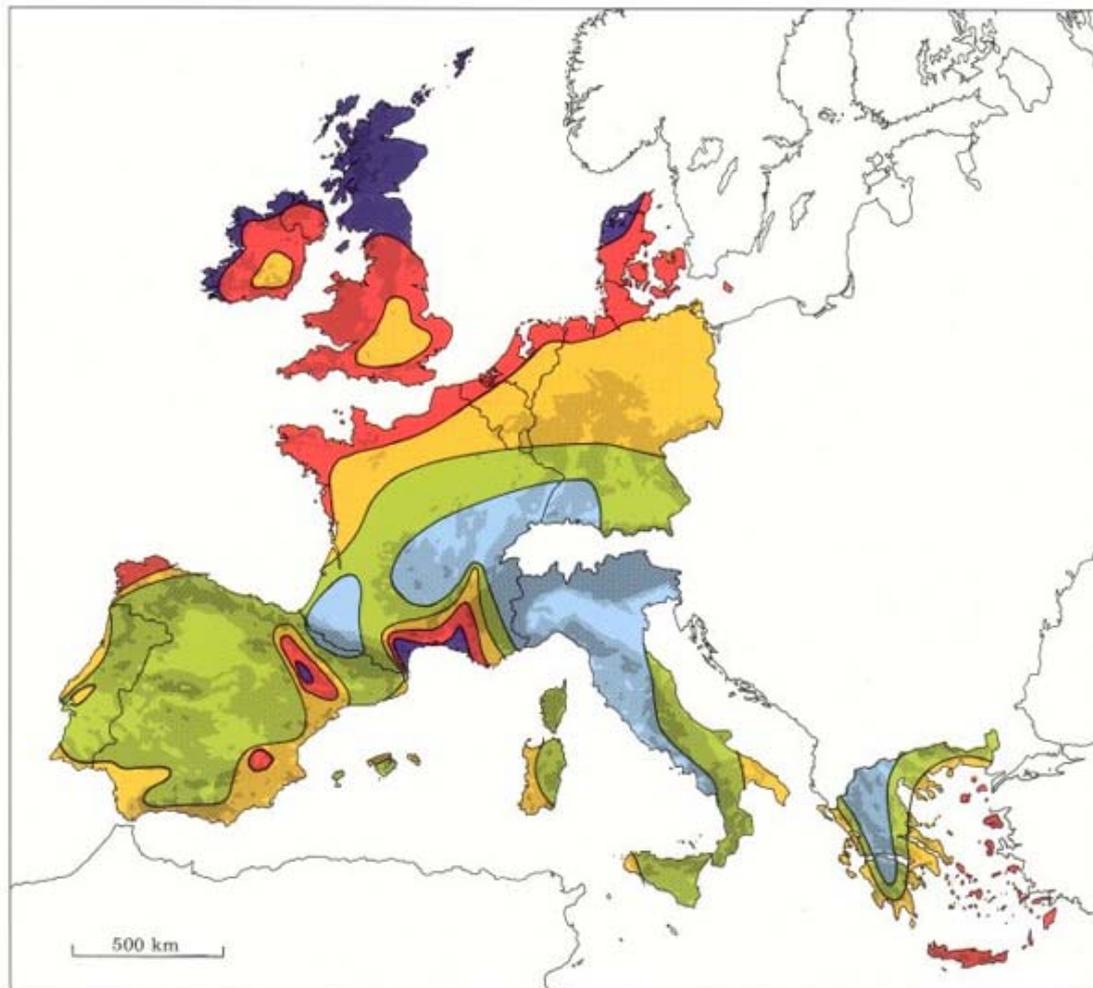


Figura 2.8: Capacidad instalada en Europa (GW).

Fuente: WWEA

Dentro de Europa, Alemania (capacidad total de 27.214 MW, incremento de 1.493 MW después de un aumento de 1.880 MW en 2009) y España (en total 20.676 MW, incremento de 1.516 MW después de un aumento de 2.460 MW en 2009) son, con diferencia, los mayores mercados aunque con tasas de crecimiento muy modestas (5,6% y 8,0%).

En el siguiente gráfico se observa el mapa eólico en Europa así como su aprovechamiento mas acusado en las costas del norte e Inglaterra donde la intensidad del viento es mayor.



Wind resources ¹ at 50 metres above ground level for five different topographic conditions										
	Sheltered terrain ²		Open plain ³		At a sea coast ⁴		Open sea ⁵		Hills and ridges ⁵	
	$m s^{-1}$	Wm^{-2}	$m s^{-1}$	Wm^{-2}	$m s^{-1}$	Wm^{-2}	$m s^{-1}$	Wm^{-2}	$m s^{-1}$	Wm^{-2}
Dark Blue	> 6.0	> 250	> 7.5	> 500	> 8.5	> 700	> 9.0	> 800	> 11.5	> 1800
Red	5.0-6.0	150-250	6.5-7.5	300-500	7.0-8.5	400-700	8.0-9.0	600-800	10.0-11.5	1200-1800
Orange	4.5-5.0	100-150	5.5-6.5	200-300	6.0-7.0	250-400	7.0-8.0	400-600	8.5-10.0	700-1200
Yellow	3.5-4.5	50-100	4.5-5.5	100-200	5.0-6.0	150-250	5.5-7.0	200-400	7.0- 8.5	400- 700
Light Blue	< 3.5	< 50	< 4.5	< 100	< 5.0	< 150	< 5.5	< 200	< 7.0	< 400

Figura 2.9: Mapa eólico de Europa

Fuente: EWEA

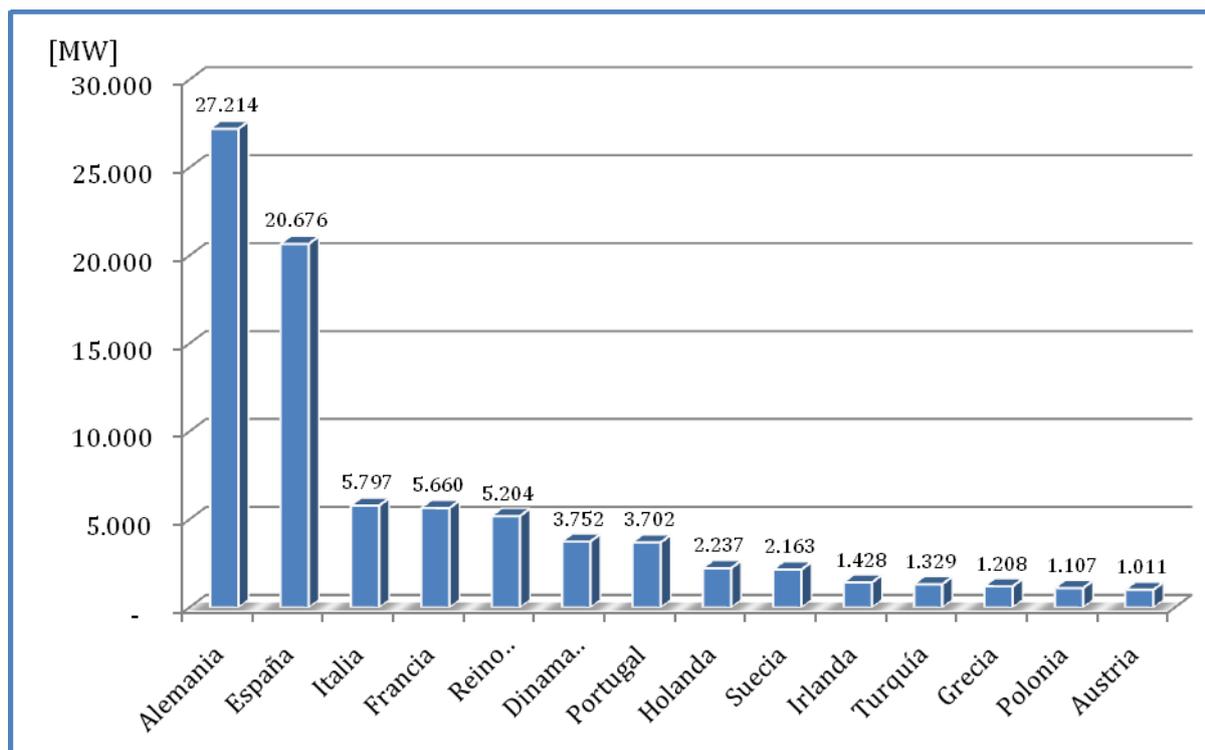


Figura 2.10: Capacidad instalada en algunos países de Europa en 2010.

Fuente: AEE y propia

Los fabricantes de aerogeneradores daneses, alemanes y españoles siguen siendo líderes. Sin embargo, competidores especialmente de Asia (China, India, Corea y Japón) han sido capaces de aumentar sus cuotas de mercado en mercados nacionales e internacionales.

PERSPECTIVAS FUTURAS:

A pesar del estancamiento en 2010, las perspectivas generales en Europa son buenas, teniendo en cuenta los objetivos ambiciosos de muchos países. Según un informe de World Wind Energy Association [12]:

- En Alemania, se espera llegar a una cuota de energía eólica en el suministro de electricidad de 20-25 % para el año 2020. Esto sería equivalente a 45 GW de instalaciones en tierra, más 10 GW Offshore.
- En España, se esperan 38 GW de capacidad instalada para el año 2020 incluyendo 35 GW en tierra y 3 GW de energía eólica Offshore.

Capítulo2: Aprovechamiento del recurso Eólico

- El Reino Unido, líder mundial en energía eólica Offshore, ha establecido un objetivo para el año 2020, de 15 GW en tierra y 13 GW Offshore.
- Italia fijó como objetivo llegar a los 12,680 GW instalados al 2020 lo que sería más del doble de su capacidad instalada.
- Polonia espera instalar 8,6 GW antes del 2020.

Europa sigue siendo el continente líder en instalaciones Offshore, donde se pueden encontrar el 96% de los aerogeneradores instalados fuera de costa.

Otra tendencia importante ha comenzado en Alemania: la repotenciación de viejos aerogeneradores: En 2010, 183 MW fueron reemplazados por máquinas más grandes. Este mercado se espera que crezca sustancialmente en el futuro.

Otra tendencia importante se encuentra en Dinamarca, la cuna de los parques eólicos instalados por la comunidad. El país volvió a introducir incentivos especiales para la propiedad comunitaria de los parques eólicos.

Teniendo en cuenta la gran aceptación que ha tenido, los políticos en otras partes del mundo deben sentirse alentados a adoptar el modelo danés.

Todas estas expectativas y perspectivas futuras ayudarán a conseguir los objetivos generales de la Unión Europea establecidos en la Directiva 2009/28/CE, que establecía una contribución de las energías renovables en un 20% al consumo de Energía primaria en el horizonte del año 2020.

2.1.3 A nivel nacional

SITUACION ACTUAL:

En el caso de España, la energía eólica es la tercera fuente de generación eléctrica, por detrás del gas y la nuclear. En el año 2010, cubrió el 16,6% de la demanda eléctrica del país. España es el cuarto país del mundo por potencia eólica instalada, tras Estados Unidos, Alemania y China como se observa en la tabla 1.1.

Datos básicos de la eólica en España, según la Asociación Empresarial Eólica [15]:

Capítulo2: Aprovechamiento del recurso Eólico

- La potencia instalada a finales de 2010 era de 20.676 MW.
- La eólica fue la tercera tecnología en el sistema eléctrico en 2010, con una producción de 42.692.000 MWh, y la primera en marzo de 2011.
- Por sólo 1,3 euros al mes por cada hogar medio, cubre el consumo eléctrico de 10 millones de familias.
- Más de más de 30.000 personas trabajan en el sector en nuestro país.
- Exporta tecnología por más de 2.106 millones de euros al año.
- Invierte en I+D más de 156 millones de euros anuales.
- La eólica aporta directamente e indirectamente 2.984 millones de euros al PIB en el que ya representa el 0,28%.

Desde los noventa, la trayectoria de la potencia eólica instalada en nuestro país ha ido en continuo ascenso, también es cierto que ha habido años mejores y años “menos buenos”. Aunque 2010 no se puede tachar de mal año, ya que se instalaron 1.516 MW nuevos, hasta los 20.676 MW de potencia acumulada, sí es cierto que ha sido uno de los “menos buenos” en la última década.

Eso sí, no se puede reprochar al sector eólico que no cumpla los objetivos. Año tras año queda reflejado el crecimiento que ha superado ligeramente el objetivo del Plan de Energías Renovables 2005-2010 (de los 20.155 MW estipulados a los 20.676 MW).

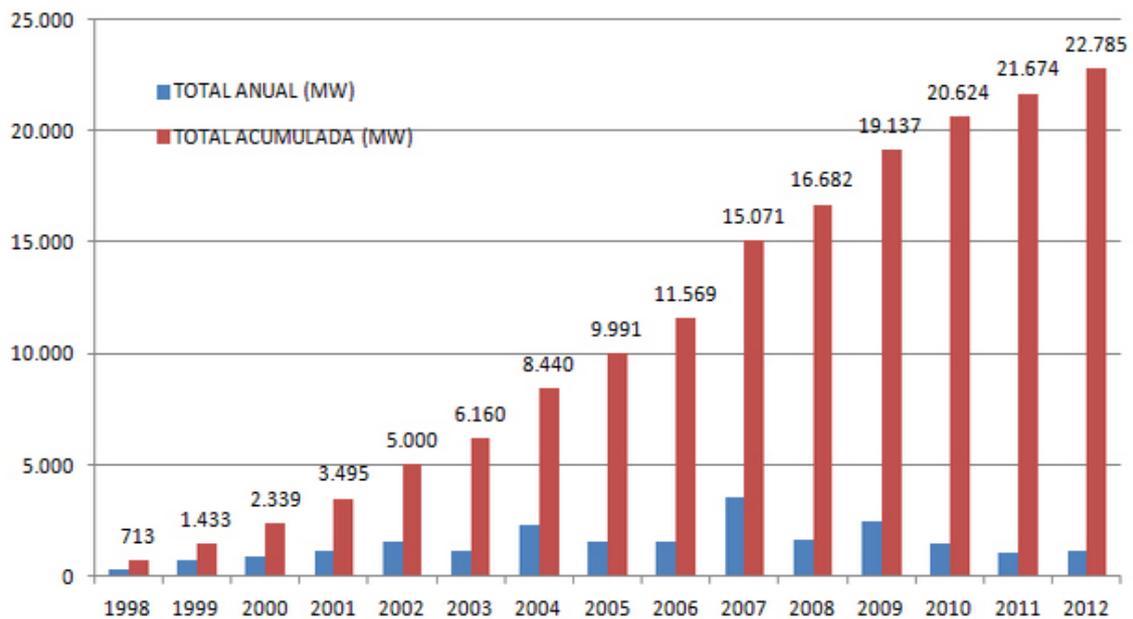


Figura 2.11: Evolución anual de la potencia eólica acumulada en España (1998-2012).

Fuente: AEE

En cuanto a la potencia instalada por Comunidades Autónomas, se puede observar en la siguiente tabla que Castilla y León presenta la mayor potencia instalada con un total de 4.803 MW seguida de cerca por Castilla la Mancha y Canarias se encuentra en una posición retrasada debido a la poca extensión de su territorio en comparación con las demás CC.AA. que están por delante.

Tabla 2.2: Potencia eólica instalada por Comunidades Autónomas 2012.

Fuente: AEE

Comunidad Autónoma	Potencia instalada en 2012 (MW)	Porcentaje sobre el total instalado en 2012	Potencia acumulada a cierre de 2012 (MW)	% sobre total	Tasa de variación (%)	Nº de parques (*)
Castilla y León	277,5	25,0%	5.510,6	24,18%	5,3%	236
Castilla La Mancha	70,8	6,4%	3.806,5	16,71%	1,9%	139
Galicia	31,4	2,8%	3.311,5	14,53%	1,0%	156
Andalucía	196,3	17,7%	3.263,2	14,32%	6,4%	149
Aragón	83	7,5%	1.893,3	8,31%	4,6%	87
Cataluña	256,7	23,1%	1.258,1	5,52%	25,6%	45
Comunidad Valenciana	19	1,7%	1.189,0	5,22%	1,6%	38
Navarra	3	0,3%	979,9	4,30%	0,3%	47
Asturias	84	7,6%	512,5	2,25%	19,6%	20
La Rioja	0	0%	446,6	1,96%	0,0%	14
Murcia	72	6,5%	262,0	1,15%	37,9%	14
Canarias	18,2	1,6%	160,1	0,70%	12,8%	54
País Vasco	0	0%	153,3	0,67%	0%	7
Cantabria	0	0%	35,3	0,15%	0%	3
Baleares	0	0%	3,7	0,02%	0%	46
TOTAL	1.111,8		22.785,5		5,13%	1.055

En los últimos años han existido Comunidades Autónomas que por diversos motivos, la crisis es la más importante, han instalado pocos MW incluso en algunos casos ninguno, es el caso de Baleares, Canarias, La Rioja, País Vasco, Navarra y la Comunidad Valenciana.

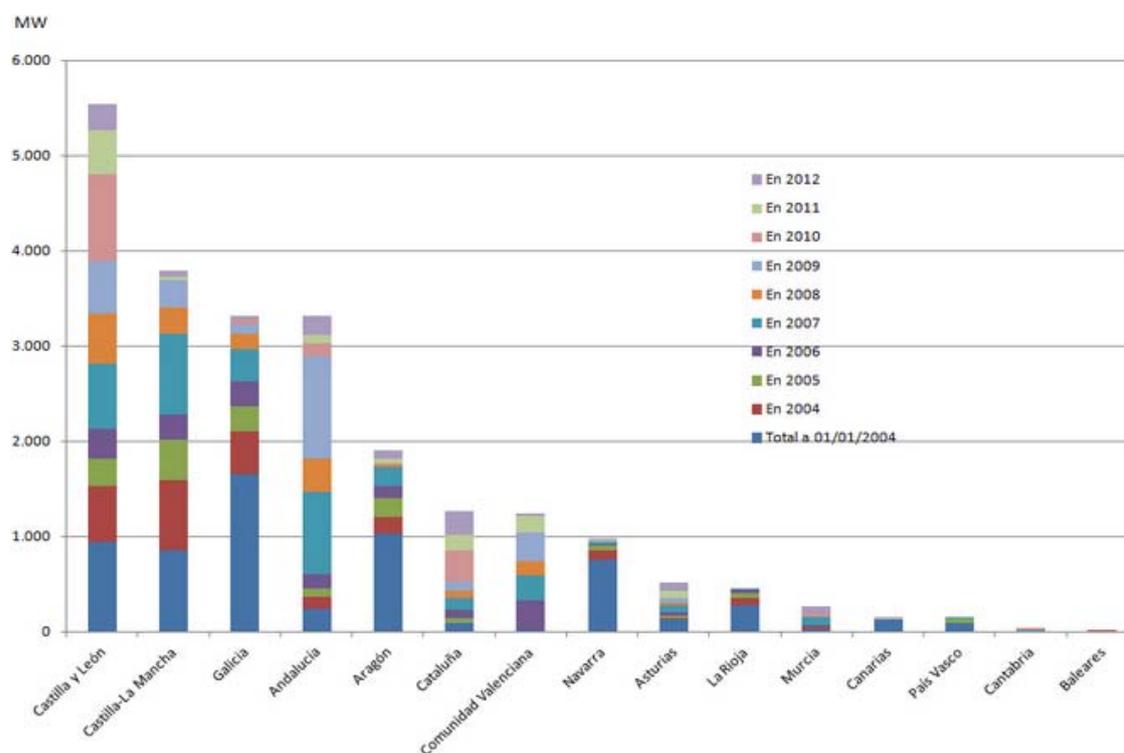


Figura 2.12: Evolución de la potencia eólica instalada por Comunidades Autónomas (2004-2012).

Fuente: AEE

PERSPECTIVAS FUTURAS:

La Directiva 2009/28/CE de la Unión Europea estableció a España unos objetivos específicos:

- Una contribución de las energías renovables en un 40% a la demanda de Energía Eléctrica en el horizonte del año 2020.
- Una contribución de las energías renovables en un 20% al consumo de Energía primaria en el horizonte del año 2020.

Como se ha comentado anteriormente (apartado 1.1.1) ha la vista de este escenario han saltado líneas de actuación y España ha respondido ante esta situación redactando el PANER [16] y el PER 2011-2020 [5].

- En España, se esperan 38 GW de capacidad instalada para el año 2020 incluyendo 35 GW en tierra y 3 GW de energía eólica Offshore.

En la figura 2.13 se observa un gráfico comparativo entre la situación actual y las perspectivas futuras.

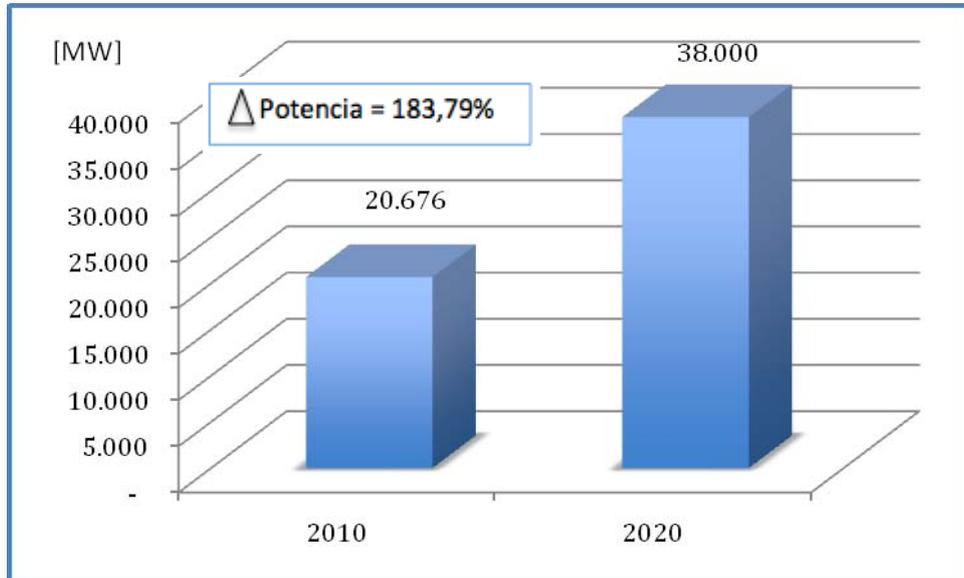


Figura 2.13: Comparación entre la potencia eólica instalada y prevista para 2020 en España.

Fuente: AEE

2.1.4 A nivel de la Región de Canarias

SITUACION ACTUAL:

Según un informe de la potencia eólica instalada en 2011 por islas es la siguiente [17]:

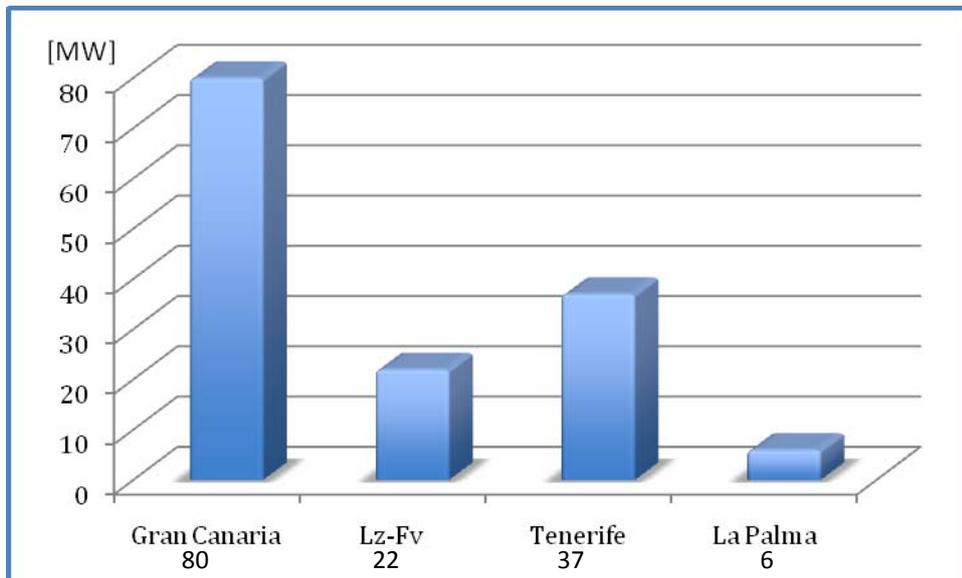


Figura 2.14: Potencia eólica instalada en Canarias

Fuente: REE y propia

Los parques eólicos instalados han ido ocupando los emplazamientos de mayor potencial eólico de cada una de las islas.

Los últimos parques eólicos 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.

Canarias fue pionera en la instalación de los primeros parques eólicos en España, junto con Tarifa (Cádiz) y La Muela (Zaragoza). Sin embargo, su peculiar sistema "aislado", hace que se hayan limitado el número de parques eólicos para asegurar la estabilidad del sistema.



Figura 2.15: Mapa de instalaciones eólicas en Canarias

Fuente: ITC

En la figura anterior se observa que la mayor concentración de instalaciones eólicas en Canarias radica en el sureste de Gran Canaria por ser ésta una región con un gran caudal de viento y una orografía que lo permite. [6]

La potencia eólica en Canarias ha ido aumentando lentamente con el paso de los años. Como se puede observar en la siguiente figura.

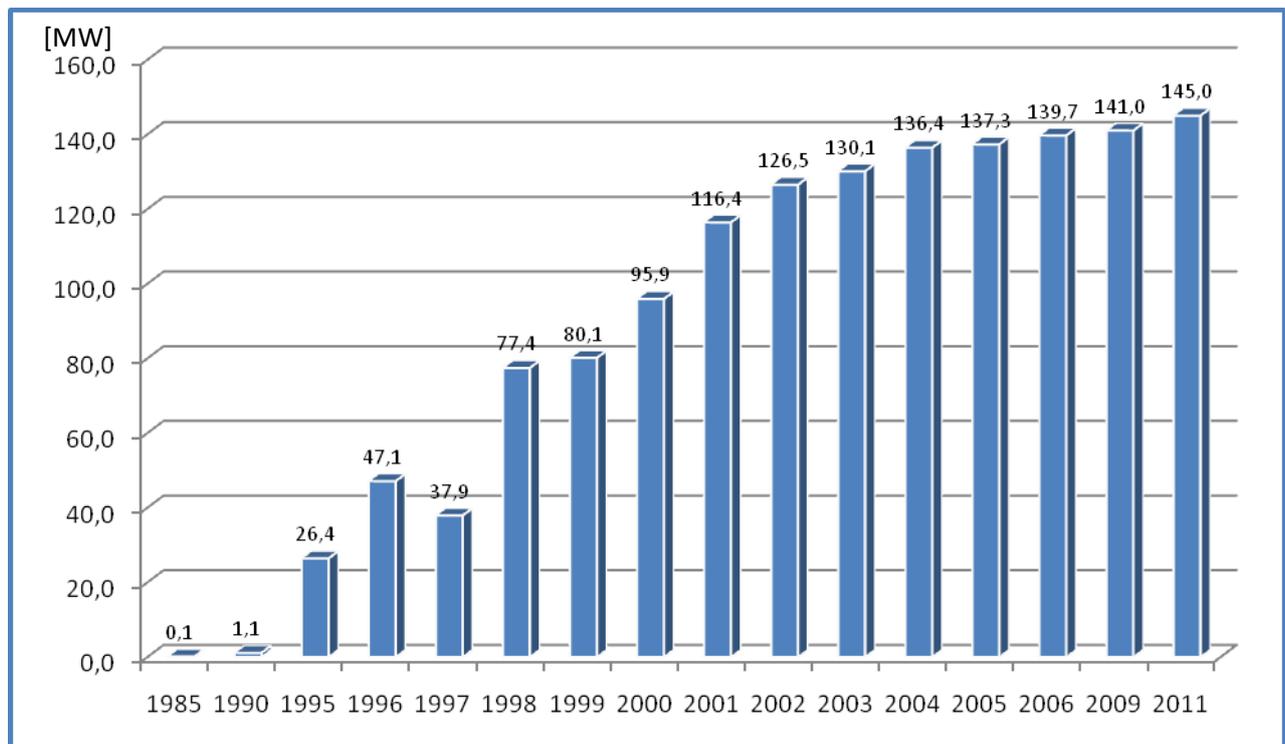


Figura 2.16: Evolución de la potencia eólica instalada en Canarias.

Fuente: REE

PERSPECTIVAS FUTURAS:

Para cumplir los objetivos específicos establecidos por el PER 2005-2010, a nivel regional, se elaboró el PECAN [9] que establece los siguientes objetivos:

- Alcanzar una contribución de las EERR a la Energía primaria del 8%.
- Alcanzar una contribución de las EERR a la Energía Eléctrica del 30%.
- Tener instalados en el año 2015 160 MW y 1025 MW de potencia fotovoltaica y eólica, respectivamente.

En la tabla siguiente se muestra la estimación de potencia eólica en Canarias prevista en el PECAN para el periodo 2005-2015, así como la evolución real de estas magnitudes hasta el 2010 y las nuevas previsiones para el periodo 2011-2015.

Tabla 2.3: Comparativa de la potencia eólica instalada (2005-2010) y nueva previsión de potencia (2011-2015), con la previsión PECAN (2005-2015). CANARIAS

Fuente: Revisión PECAN

Año	CANARIAS (MW)			Tasa de variación anual		
	Revisión	PECAN	Diferencia	Revisión	PECAN	Diferencia
2005	137,11	136,40	0,5%			
2006	137,11	136,40	0,5%	0,0%	0,0%	0,0%
2007	139,48	136,40	2,3%	1,7%	0,0%	1,7%
2008	139,48	309,00	-54,9%	0,0%	126,5%	-126,5%
2009	139,48	544,52	-74,4%	0,0%	76,2%	-76,2%
2010	139,48	590,78	-76,4%	0,0%	8,5%	-8,5%
2011	205,06	656,00	-68,7%	47,0%	11,0%	36,0%
2012	369,59	656,00	-43,7%	80,2%	0,0%	80,2%
2013	522,62	774,21	-32,5%	41,4%	18,0%	23,4%
2014	675,65	964,12	-29,9%	29,3%	24,5%	4,8%
2015	1025,00	1.025,00	0,0%	51,7%	6,3%	45,4%

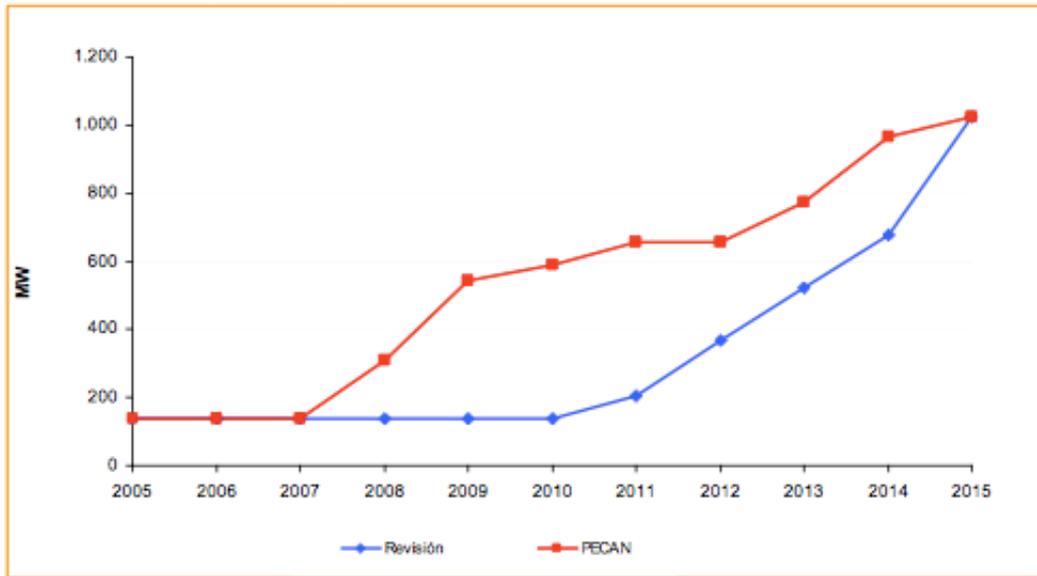


Figura 2.17: Comparativa de potencia eólica instalada

Fuente: revisión PECAN

La potencia eólica instalada en Canarias a finales del 2011 era de 145 MW, que comparándola con la que se pretende tener instalada con el horizonte de 2015, quedaría por instalar 880 MW [8]. Esto supone un incremento de la potencia eólica instalada del 706,90%, tal y como se observa en la figura 2.14.

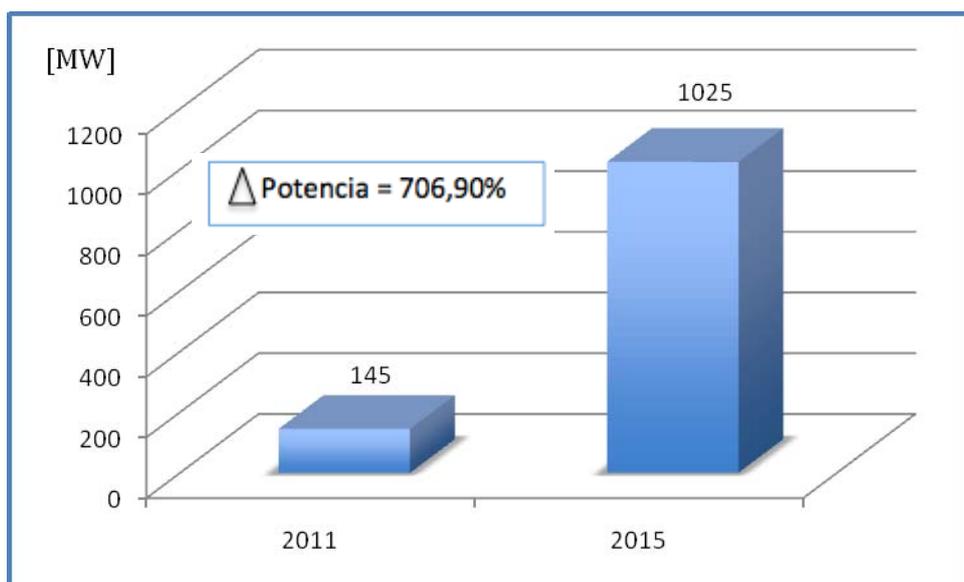


Figura 2.18. Comparación entre la potencia eólica instalada y prevista para 2015 en Canarias

Fuente: Decreto 32/2006 y propia

Esta potencia eólica se instalará generalmente en zonas de menos 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).

La instalación de los nuevos parques eólicos en Canarias es inminente, lo que multiplicará por cuatro la capacidad de generación de energía eólica en los próximos dos años, avanzando hacia el objetivo de cubrir con energías renovables el 30% de la demanda eléctrica en Canarias.

Según el Decreto 32/2006 [7] la potencia eólica máxima que podrá estar instalada y conectada a la red en el año 2015 en los sistemas eléctricos insulares, no podrá sobrepasar los valores siguientes:

Tabla 2.4: Potencia instalada en Canarias en el año 2015

Fuente: Decreto 32/2006

SISTEMA ELÉCTRICO	POTENCIA (MW)
Gran Canaria	411
Lz-Fv	162
Tenerife	402
La Palma	28
La Gomera	8
El Hierro	14
TOTAL	1025

NORMATIVA NACIONAL:

- Orden ITC/3353/2010, de 28 de diciembre, por la que se establecen los peajes de acceso a partir de 1 de enero de 2011 y las tarifas y primas de las instalaciones del régimen especial.

- Real Decreto 1614/2010, de 7 de diciembre, por el que se regulan y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica a partir de tecnologías solar termoeléctrica y eólica.

- Corrección de errores del Real Decreto 1565/2010, de 19 de noviembre, por el que se regula y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica en régimen especial.

- Real Decreto 661/2007, de 25 de mayo, por el que se regula la actividad de producción de energía eléctrica en régimen especial.

- Corrección de errores del Real Decreto 661/2007, de 25 de mayo, por el que se regula la actividad de producción de energía eléctrica en régimen especial. BOE 26/7/07.

- Real Decreto-ley 6/2009, de 30 de abril, por el que se adoptan determinadas medidas en el sector energético y se aprueba el bono social

- Real Decreto 1565/2010, de 19 de noviembre, por el que se regulan y modifican determinados aspectos relativos a la actividad de producción de energía eléctrica en régimen especial.

Capítulo2: Aprovechamiento del recurso Eólico

- Real Decreto 198/2010, de 26 de febrero, por el que se adaptan determinadas disposiciones relativas al sector eléctrico a lo dispuesto en la Ley 25/2009, de modificación de diversas leyes para su adaptación a la ley sobre el libre acceso a las actividades de servicios y su ejercicio.
- Real Decreto 1028/2007, de 20 de julio, por el que se establece el procedimiento administrativo para la tramitación de las solicitudes de autorización de instalaciones de generación eléctrica en el mar territorial.

NORMATIVA AUTONÓMICA:

- DECRETO 121/2011, de 17 de mayo, que modifica parcialmente el Decreto 32/2006.
- DECRETO 7/2011, de 20 de enero, que modifica el 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.
- 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. (BOCA N° 61/2006).
- DECRETO 141/2009, de 10 de noviembre, por el que se aprueba el Reglamento por el que se regulan los procedimientos administrativos relativos a la ejecución y puesta en servicio de las instalaciones eléctricas en Canarias.
- RESOLUCIÓN de 4 de octubre de 2006, de la Secretaría General de Energía, por la que se aprueba el procedimiento de operación 12.3 Requisitos de respuesta frente a huecos de tensión de las instalaciones eólicas.

Capítulo2: Aprovechamiento del recurso Eólico

- Orden de 15 de Noviembre de 2006, por la que se regulan las condiciones Técnico-Administrativas de las instalaciones eólicas ubicadas en Canarias. (BOCA N° 225/2006).

2.2 Referencias

- [1]: WWINDEA. Estructura de los molinos de vientos. <http://www.wwindea.org/technology/ch01/estructura-en.htm>. 2014.
- [2]: WWEA. Instalaciones Eólicas Mundiales. <http://www.wwindea.org/information-2/information>. 2014.
- [3]: Ayuntamiento de Pamplona, Área de Medio Ambiente y Sanidad. Energía Eólica. <http://www.pamplona.es/VerPagina.asp?idPag=208&idioma=1>. 2014.
- [4]: Generador Eléctrico. Componentes eléctricos y electrónicos de las energías renovables. <https://generador-electrico.com/tienda/es/43-acumuladores>. 2015.
- [5]: Ministerio de Industria, Turismo y Comercio. Plan de Energías Renovables 2011-20. <http://www.minetur.gob.es/energia>. 2014.
- [6]: Instituto Tecnológico de Canarias. Eólica. <https://es.scribd.com/collections/2860868/Energia>. 2014.
- [7]: Gobierno de Canarias. 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. 2015.
- [8]: Gobierno de Canarias. Informe de seguimiento del Plan Energético de Canarias. http://www.gobiernodecanarias.org/energia/doc/planificacion/pecan/2009_Informe_Seguimiento_PECAN.pdf. 2009.
- [9]: Gobierno de Canarias. Plan energético de Canarias. <http://www.gobiernodecanarias.org/energia/doc/planificacion/pecan/pecan2007.pdf>. 2009.
- [10]: José María Fernández Salgado. Guía completa de la energía eólica. Editorial AMV Ediciones. 2013.
- [11]: Luis Romero Lozano. Programación, organización y supervisión del aprovisionamiento y montaje de instalaciones de energía eólica. Editorial Paraninfo. 2013.
- [12]: World Wind Energy Association. Informe para el desarrollo y promoción de la energía eólica. <http://www.wwindea.org/world-wind-world-report-2012-launched>. 2014.
- [13]: The Schumacher Centre for Technology & Development. "Wind for electricity generation", en http://practicalaction.org/docs/technical_information_service. 2013.
- [14]: Neg-Micon, "A new millennium", Powerful News, Vol. 1, no. 3, 2002.
- [15]: AEEOLICA. La eólica en España. <http://www.aeeolica.org/es/sobre-la-eolica/la-eolica-en-espana>. 2015.

Capítulo2: Aprovechamiento del recurso Eólico

[16]: Ministerio de Industria, Turismo y Comercio. Plan de Acción Nacional de Energías Renovables de España (PANER) 2011 – 2020. <http://www.minetur.gob.es/energia/paner>. Junio 2010.

[17]: REE. Balance del sistema eléctrico canario 2010. Red de transporte y planificación de infraestructuras eléctricas 2008-2016. http://www.ree.es/sala_prensa/web/inc/fichero.aspx?ruta=especiales/archivos&fichero=pjb_wxf5un6ka.pdf. 2015.

CAPÍTULO 3

Predicción de la potencia eléctrica de origen eólico

INDICE

3.1	Introducción.....	56
3.2	La variabilidad de la potencia eólica.....	60
3.3.	Aspectos principales del problema de predicción de potencia eólica.....	66
3.3.1	Modelado del proceso de conversión de energía.....	67
3.3.2	Importancia de las predicciones para el operador del sistema eléctrico.....	69
3.4	Bibliografía de los modelos de predicción a corto plazo de la producción eléctrica de origen eólico.....	72
3.4.1	Evaluación de modelos de predicción.....	72
3.4.2	Familias de modelos de predicción de la producción eléctrica de origen eólica en el corto plazo.....	75
3.5	Error de la predicción de la potencia eólica.....	81
3.5.1	Definición del error de predicción.....	82
3.5.2	Evaluación del error orientada a la medida de parámetros.....	83
3.5.3	Evaluación del error orientada a la distribución del error.....	86
3.6.	Beneficios y penalizaciones de la predicción eólica.....	88
3.6.1	Desvíos en la predicción.....	90
3.6.2	Exención del coste del desvío.....	92
3.7	Referencias.....	94

ÍNDICE DE FIGURAS

Figura 3.1: Causas del viento a escala global

Figura 3.2: Espectro característico de Van der Hoven

Figura 3.3: Ejemplo de función de distribución de Weibull ajustada a las datos de viento en una zona

Figura 3.4: Curva de potencia característica de un aerogenerador

Figura 3.5: Curva de potencia estimada y medida de un parque eólica de 21MW en Dinamarca en un periodo de 2000 horas

Figura 3.6: Histograma del error normalizado de predicciones de horizonte $K=5$ para el parque PE3

ÍNDICE DE TABLAS

Tabla 3.1: Resumen de características de modelos de predicción de la primera familia

Tabla 3.2: Resumen de características de modelos de predicción de la segunda familia

3.1 Introducción

El sector de la energía eólica presenta claro liderazgo entre las posibilidades actuales de energías renovables. En muchos mercados eléctricos donde un porcentaje significativo de producción proviene de este tipo de instalaciones, empiezan a producirse problemas de integración debido a su enorme variabilidad e imprevisibilidad. A la vez, la Unión Europea ha emprendido una fuerte apuesta por el desarrollo de un mercado liberalizado de la producción eléctrica. Por ello, con el paso de los años la energía eólica perderá los beneficios que pueda poseer en la actualidad y tendrá que actuar bajo unas reglas comunes. En este caso, la intermitencia de la energía eólica, provoca penalizaciones por desvíos en la producción respecto a lo acordado en el mercado.

En este contexto general, conseguir una buena predicción eólica a corto plazo (lo suficiente para operar en el mercado de la electricidad puede ser menos de 48 horas) es fundamental para conseguir buenos resultados económicos.

El fuerte impulso que se ha dado a las fuentes de energía de origen renovable ha propiciado que en los últimos años se haya producido un gran aumento de la potencia instalada, y entre ellas, la energía eólica ha sido la que ha tenido un mayor auge, debido principalmente a la gran madurez de la tecnología, resultando en un coste por megavatio instalado cada vez menor.

Como contrapartida, la generación eólica conlleva ciertos inconvenientes. Por un lado, la gran variabilidad del viento, y por tanto de la generación eólica, complica su integración en el sistema eléctrico. Además, algunos generadores pueden desconectarse del sistema ante perturbaciones como los huecos de tensión, descensos bruscos en la tensión que tienen lugar cuando se produce un cortocircuito en el sistema [1]. Estas perturbaciones pueden provocar una pérdida súbita de generación eólica en el sistema, que puede poner en riesgo la seguridad del suministro [2]. Sin embargo, la reciente incorporación de mejoras tecnológicas en el comportamiento de los aerogeneradores frente a perturbaciones en la red comienza a permitir un alto grado de penetración de la energía eólica sin comprometer en demasía la seguridad del abastecimiento eléctrico.

Este tipo de generación, que en la mayoría de los casos es de potencias relativamente reducidas, conlleva otras ventajas, como la disminución de las pérdidas por transporte en la red, gracias a que la generación se acerca más al consumo [3] y [4].

En los últimos años se ha dado un gran impulso a las energías renovables, entre ellas destaca la energía eólica con un mayor auge en potencia instalada debido principalmente a los avances de la tecnología asociada y a su elevada disponibilidad geográfica, ya que hay corrientes de aire en casi cualquier lugar del planeta.

Por otro lado, la generación eólica conlleva ciertos inconvenientes. La gran variabilidad del viento, y por tanto de la generación eólica, complica su integración en el sistema eléctrico. Además, algunos generadores pueden desconectarse del sistema ante perturbaciones como los huecos de tensión, descensos bruscos en la tensión que tienen lugar cuando se produce un cortocircuito en el sistema [1]. Estas perturbaciones pueden provocar una pérdida súbita de generación eólica en el sistema, que puede poner en riesgo la seguridad del suministro. Sin embargo, la reciente incorporación de mejoras tecnológicas en el comportamiento de los aerogeneradores frente a perturbaciones en la red comienza a permitir un alto grado de penetración de la energía eólica sin comprometer la seguridad del abastecimiento eléctrico.

Gracias a las mejoras en el comportamiento de los aerogeneradores, a la continua bajada en el coste por megavatio instalado de potencia eólica, y a los avances en los métodos de apoyo a la programación y gestión de esta energía, la eólica se ha convertido en la fuente de energía renovable que más se ha desarrollado en los últimos años [5].

La importancia de las predicciones radica en la ayuda que aportan para planificar y anticiparse a los valores futuros que afectarán a un sistema, ayudando a gestionar la adquisición de los recursos necesarios con antelación suficiente, o sirviendo como herramienta para maximizar la rentabilidad mediante la toma de decisiones que maximicen los beneficios de una actividad.

Los primeros esfuerzos por crear algoritmos de predicción en el ámbito de los sistemas eléctricos se dedicaron a la predicción de la demanda eléctrica [8]. Desde el punto de vista del operador del sistema eléctrico o TSO, las predicciones de demanda han ayudado a la toma de decisiones como la puesta en funcionamiento con antelación suficiente de unidades de producción eléctrica o la programación del mantenimiento de elementos del sistema eléctrico. Según agentes de mercado, la predicción de demanda ha sido una herramienta utilizada para optimizar sus ofertas de energía al mercado eléctrico con el objetivo de maximizar la rentabilidad.

Pero el gran auge que han tenido las fuentes de energía renovables durante los últimos años ha obligado a plantearse un nuevo problema de previsión, el de conocer con la antelación suficiente la energía que van a generar estas centrales. Dado que el mayor auge en el ámbito de las energías renovables lo ha experimentado la energía eólica, es en este sector en el que se han venido aplicando mayores esfuerzos por crear herramientas de predicción de energía fiables y eficientes, que ayuden a integrar esta forma de energía en la red [9],[10].

La eólica como se ha comentado, es una forma de generación no programable, ya que solo se produce energía cuando sopla el viento, que puede llegar a ser muy variable incluso en el corto plazo, con posibilidad de intermitencia y grandes cambios en intervalos cortos de tiempo. Por ello, es difícil conocer con antelación y precisión suficiente la cantidad de energía eólica con la que podremos contar en cada momento. Esta variabilidad hace especialmente compleja su operación, por lo que su producción futura tiene que ser estimada o prevista, viniendo esta previsión de potencia futura inevitablemente afectada por un error o incertidumbre de predicción.

Si el viento disminuye, la potencia generada en los parques eólicos también disminuye, y esa falta de potencia debe ser reemplazada por otras fuentes de generación con una reserva suficiente en magnitud y velocidad de respuesta para que la demanda eléctrica no se vea afectada. En otras ocasiones, puede ocurrir que no se pueda integrar en el sistema toda la producción eólica disponible, ya que la energía eólica no se genera de acuerdo a las necesidades de consumo, y sea necesario reducir el suministro de esta fuente de energía. Por todo esto, la predicción de generación eólica se ha convertido en un tema clave para hacer factible el desarrollo e implantación de la energía eólica, y su integración en el sistema eléctrico.

Desde el punto de vista de generación eólica, o de cualquier otra fuente de energía renovable, su predicción resulta útil tanto para el operador del sistema como para los agentes del mercado o los propietarios de parques. Así, el operador del sistema eléctrico necesita conocer con antelación suficiente la cantidad de energía eólica que será inyectada en la red para gestionar la potencia que deberán generar las centrales convencionales, con el objetivo de cubrir la demanda total del sistema. Entretanto, los agentes de mercado estarán interesados en conocer con la mayor certeza posible la potencia que generarán sus

parques eólicos con el objetivo de seguir las estrategias que resulten más rentables en el mercado de energía eléctrica. Además, los propietarios de parques eólicos también estarán interesados en conocer en qué periodos se esperan menores potencias generadas en sus instalaciones, para afrontar labores programadas de mantenimiento.

El valor de la predicción de generación eólica en términos económicos tiene dos perspectivas. Por un lado, tenemos la reducción de costes de operación en el sistema originada por la reducción de reserva necesaria. Por otro lado están las posibles penalizaciones económicas que se aplican a los agentes, debidas a los desvíos en sus compromisos de generación adquiridos en el mercado de energía eléctrica.

Con un modelo de predicción [7] se pueden reducir las penalizaciones por desvíos en la oferta de venta de energía al mercado eléctrico español. El uso de predicciones eólicas contribuye así a minimizar tanto los costes de operación del sistema como a maximizar los beneficios o minimizar las penalizaciones de los agentes de mercado.

Hay que disponer de herramientas avanzadas para poder llevar a cabo una integración a gran escala de la energía eólica en el sistema eléctrico que posibilite la realización de pronósticos fiables del recurso eólico con suficiente antelación. Este aspecto es aún más acuciante en el marco de un mercado eléctrico liberalizado, donde el disponer de pronósticos acertados permite un posicionamiento favorable de la energía eólica frente a otras formas más convencionales de generación de energía eléctrica.

Actualmente, la tecnología disponible presenta dos limitaciones que justifican una mayor actividad de I+D en el campo de la predicción eólica.

- La primera limitación de las herramientas disponibles es crítica, puesto que afecta al funcionamiento de éstas. Los métodos y herramientas se encuentran limitados por su dependencia de la complejidad del terreno. En este sentido, es necesario explotar la experiencia disponible y el actual estado del arte para poder desarrollar métodos avanzados capaces de aportar un gran nivel de precisión.
- Las aplicaciones se encuentran a menudo orientadas a fines específicos. Según se evoluciona a una cada vez mayor integración de la energía eólica, mayor potencia

instalada en los parques eólicos, y progresiva liberalización de los mercados, mayor será la demanda de herramientas de predicción precisas.

3.2 La variabilidad de la potencia eólica

Desde un punto de vista macro-meteorológico, el viento es el movimiento de masas de aire en la atmósfera, generado por las diferencias de temperatura. Existen unos gradientes de temperatura en la Tierra, debidos a la desigual cantidad de calor que recibe del sol. De hecho, la zona más irradiada es el ecuador, mientras que el menos son los polos. Consecuentemente, las masas de aire más calientes del ecuador, suben de altura y se desplazan a los polos, generando a su vez un desplazamiento de las masas de aire frío al ecuador. Esta circulación de aire, es afectada también por la fuerza de Coriolis generada por el movimiento rotacional de la tierra. Esta fuerza actúa en el hemisferio Norte, acelerando el viento en la dirección de giro de la tierra (Este) si va hacia el polo o al contrario (Oeste) si va hacia el ecuador. (Figura 3.1)

De manera contraria ocurre en el hemisferio Sur. Estos vientos a gran escala que se producen en toda la atmósfera determinan lo que se denomina vientos geostróficos.

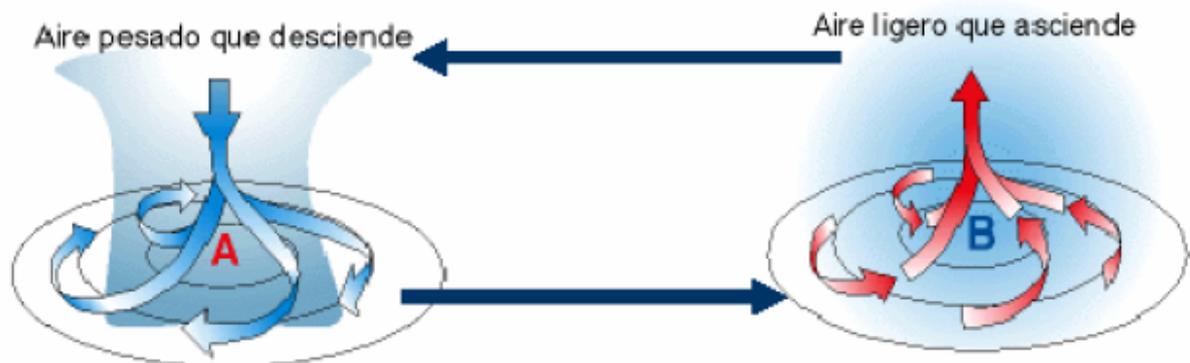


Figura 3.1: Causas del viento a escala global

Fuente: UCLM

En la capa más baja de la atmósfera, desde la superficie hasta aproximadamente los 100 metros de altura, las fuerzas de fricción debido a los obstáculos de la superficie, alteran la velocidad y la dirección del viento, produciendo unos flujos turbulentos, con velocidades del viento que varían en un amplio rango de amplitudes y frecuencia.

Adicionalmente, la presencia del mar o de grandes lagos, causa circulaciones de aire similares a las observadas en los vientos geostróficos.

La suma de todos estos vientos, provoca lo que se denominará "vientos locales". Esos vientos locales, dependerán de la localización geográfica, las características climáticas, la altura sobre el suelo, y la topografía de la superficie (rugosidad del terreno y obstáculos).

Una interesante caracterización de esos vientos locales, es comprobar la distribución de su energía cinética en el dominio de la frecuencia, en lo que se denomina un análisis de espectro de Van der Hoven.

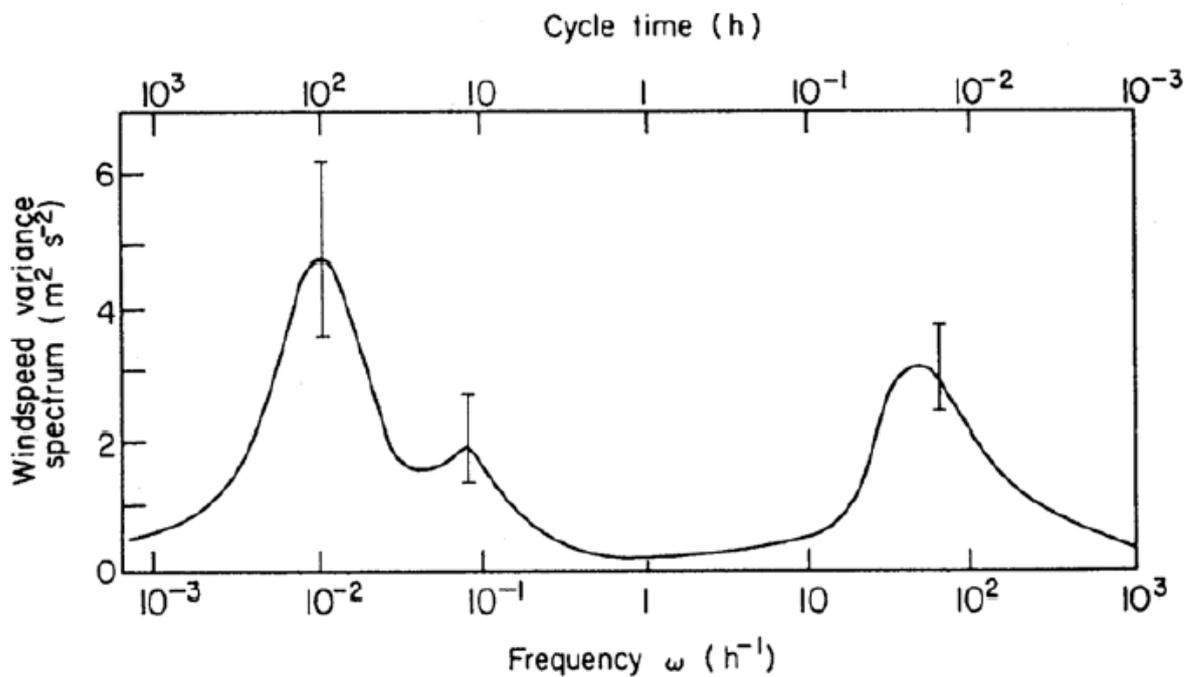


Figura 3.2: Espectro característico de Van der Hoven

Fuente: UCLM

En la Figura 3.2 se observa un espectro de Van der Hoven típico. Aunque existen variaciones al analizar en detalle esta gráfica para distintas localizaciones, siempre aparece el mismo patrón. Existen dos picos, donde se producen vientos con más energía, centrados en torno a los ciclos de 100 horas (4 días) y los ciclos de 1 minuto., los cuales están separados por un valle que cubre aproximadamente desde los 10 minutos hasta las 2 horas. Los

vientos geostróficos son responsables del pico a baja frecuencia, mientras que las turbulencias están asociadas al pico ubicado en alta frecuencia.

La clara concentración de energía en torno a dos frecuencias completamente separadas, permitiría dividir la velocidad en dos componentes:

$$\text{Ecuación 3.1} \quad v(t) = v_m(t) + v_t(t)$$

En esa ecuación V_m es la componente del viento de menor frecuencia, denominada con frecuencia velocidad media de viento, aunque no sea exactamente la media, sino la componente del viento que varía de manera más suave. V_t es la componente del viento generada por las turbulencias. Mientras que la velocidad media de viento es aprovechada por el aerogenerador para producir energía, la dinámica del aerogenerador es más lenta que la de la velocidad del viento asociada a las turbulencias, por lo que estas contribuyen en las cargas aerodinámicas que se producen en la estructura del aerogenerador, sin apenas participar en el proceso de creación de energía eléctrica. Por esta razón, ya que nuestro análisis está basado en la producción de energía eólica, a partir de ahora se hará referencia a la velocidad de media de viento, como velocidad del viento, y se denotará por $V(t)$.

Después de registrar los vientos de una zona durante años, se puede representar un histograma de las medidas. El modelo estadístico que mejor encaja con la forma obtenida de la velocidad del viento es, por consenso general, la función de distribución de Weibull. Esta función, queda definida por dos parámetros: A_w , el factor de escala y K_w , el factor de forma. Se describe como:

Ecuación 3.2
$$\Pr(v) = \frac{k_w}{A_w} \left(\frac{v}{A_w}\right)^{k_w-1} e^{-\left(\frac{v}{A_w}\right)^{k_w}}$$

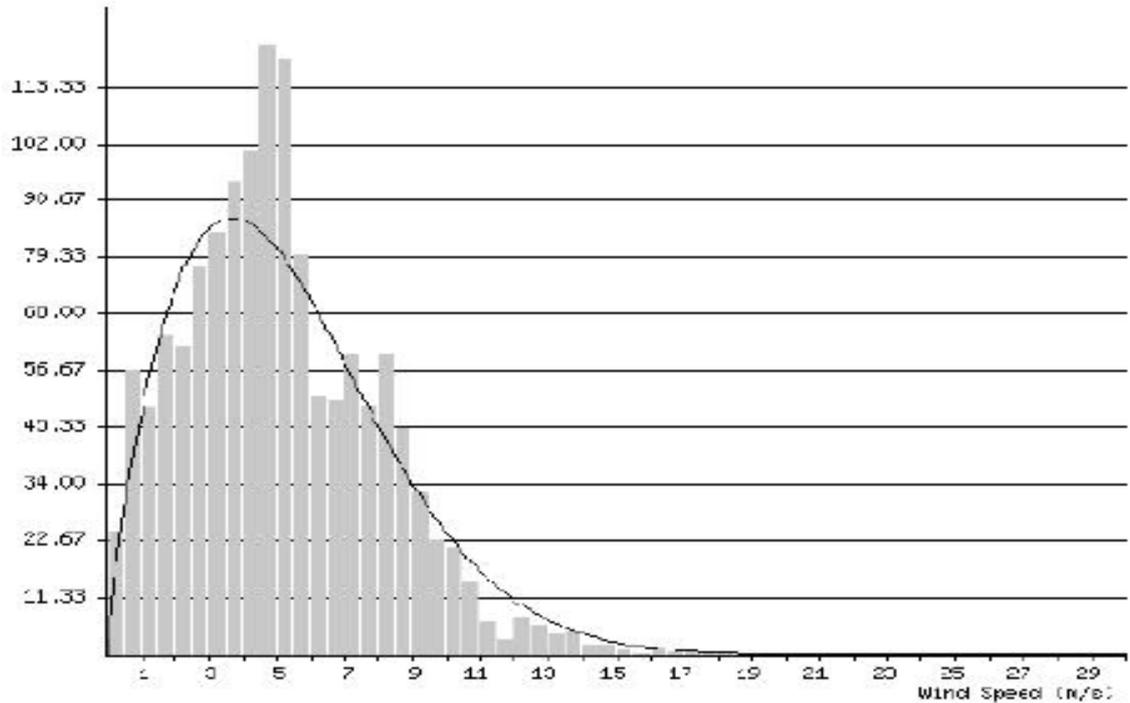


Figura 3.3: Ejemplo de función de distribución de Weibull ajustada a las datos de viento en una zona.

Fuente: UCLM

La potencia eléctrica de origen eólico es generada a través de los aerogeneradores, que transforman la energía cinética del viento en energía eléctrica. El proceso de conversión para un solo aerogenerador, suele ser descrito en base a su curva característica, denominada, curva de potencia del aerogenerador. Estas curvas, suelen tener en la realidad una forma aproximada a la presentada por el propio fabricante del aerogenerador.

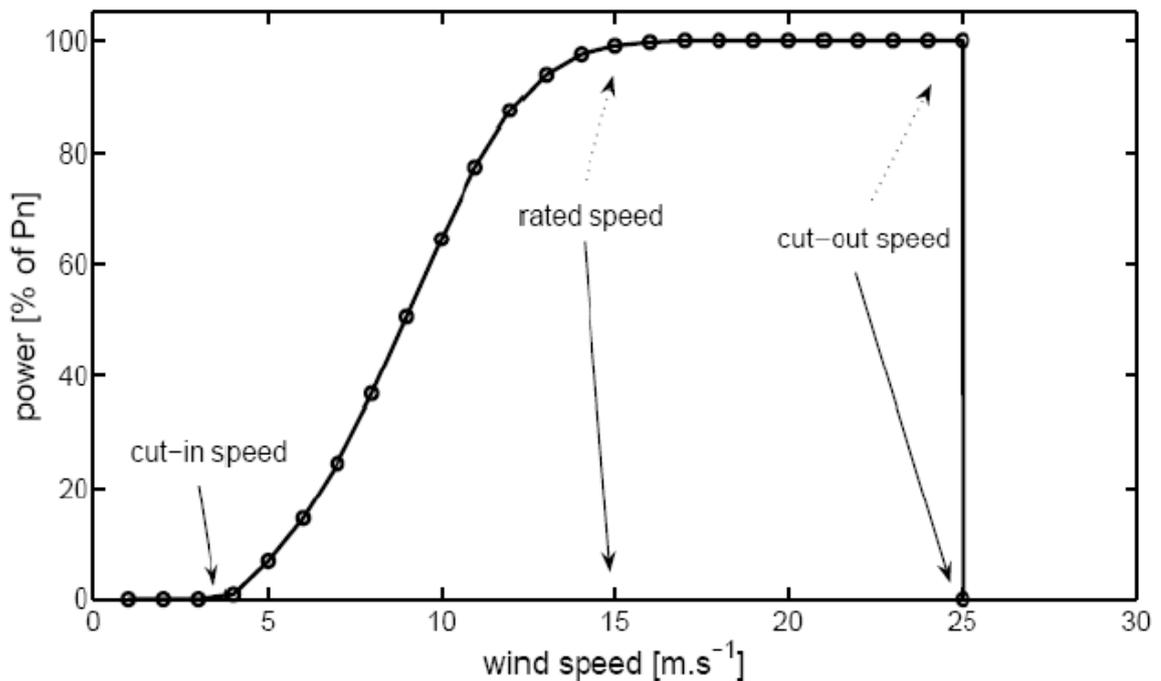


Figura 3.4: Curva de potencia característica de un aerogenerador
Fuente: UCLM

En la Figura 3.4 se observa una curva de potencia característica. La producción eléctrica es nula para bajas velocidades de viento, hasta una velocidad límite denominada “cut-in” o velocidad de conexión, suficiente para vencer el rozamiento inicial y poner en marcha el generador. A partir de ahí, la producción de potencia aumenta rápidamente con el viento, hasta la denominada potencia nominal del aerogenerador, P_n . Desde ese punto, el generador maniobra para mantenerse produciendo la máxima potencia ante mayores velocidades del viento, hasta que este llega a un valor determinado “cut-out” o velocidad de corte, donde las turbinas tienen que parar por razones de seguridad, ya que a tales vientos la estructura está soportando una gran carga aerodinámica.

El rápido aumento de la potencia eólica a partir de la velocidad “cut-in” se debe a que la potencia disponible en el viento para ser extraída, aumenta según el cubo de la velocidad, según la siguiente fórmula [25]:

$$\text{Ecuación 3.3} \quad P = \frac{1}{2} \rho_{\text{aire}} A_r v^3$$

En esta ecuación se obtiene de la fórmula de la energía cinética de un flujo de aire, $1/2mV^2$, donde la masa de aire por unidad de tiempo que atraviesa la superficie que abarca el rotor (A_r) es $VA_r\rho_{\text{aire}}$.

La ecuación 3.10 sólo representa la potencia teórica que se podría extraer del flujo de aire. En la realidad, esa potencia viene limitada por las características propias de diseño de la turbina que define el coeficiente de potencia (C_p), y por la eficiencia de la transmisión (N_t).

El coeficiente de potencia se expresa como la cantidad de potencia extraída de la potencia del viento, y se obtiene realizando una sencilla comparación entre la variación del viento antes y después de pasar por el disco del aerogenerador. Se expresa según la siguiente ecuación:

$$\text{Ecuación 3.4} \quad C_p = \frac{P_D}{P_V} = 4a(1 - a)^2$$

En la ecuación 3.4, P_D es la potencia extraída por el aerogenerador, y P_V es la potencia del viento que atraviesa el disco del aerogenerador. a se denomina factor de interferencia en el flujo axial y viene dado por el diseño del aerogenerador. El valor de a que maximiza el coeficiente de potencia C_p es según la ecuación 5, $a = 1/3$. Ese valor consigue el valor máximo de $C_p = 16/27$, conocido como límite de Betz, que indica el máximo teórico de energía que una turbina podría extraer del flujo de aire que pasa por ella.

Por estas razones, en la práctica sólo se puede extraer entre un 20% y un 30% de la energía disponible en el viento.

$$\text{Ecuación 3.5} \quad P = \frac{1}{2}\rho_{\text{aire}}C_p\eta_tA_rv^3$$

Ya que los vientos bajos son los más comunes, normalmente los aerogeneradores se encuentran trabajando en el inicio de la curva de potencia, donde pequeñas variaciones en el viento, producen grandes variaciones en la potencia. Ese factor, unido a la propia aleatoriedad del viento, explica la variabilidad de la potencia eólica.

3.3 Aspectos principales del problema de predicción de potencia eólica

El problema de la predicción se puede contemplar desde distintas escalas de tiempo:

- Hasta milisegundos a minutos: Este tipo de predicción se denomina predicción a muy corto plazo. Es utilizada para el control activo del aerogenerador.
- Hasta las siguientes 72-48 horas: Este tipo de predicción se denomina predicción a corto plazo. Es utilizada por el explotador del parque eólico para realizar las ofertas en el mercado diario.
- Para mayores escalas (semanas): Este tipo de predicción se utiliza para la programación de labores de mantenimiento.

Existen dos procesos bien diferenciados en la predicción a corto plazo de la potencia eólica. El primero es la predicción de las condiciones climáticas en el parque, y el segundo es la predicción sobre la manera en que los aerogeneradores transformarán el viento en potencia eléctrica.

PREDICCIÓN DEL VIENTO EN EL PARQUE EÓLICO

La predicción de las condiciones climatológicas se realiza mediante modelos matemáticos del clima que se denominarán como **NWP** ("Numerical Weather Predictions"). Se parte de unas condiciones iniciales, medidas por satélites, y miles de estaciones y globos meteorológicos repartidos por todo el mundo. La calidad de estas medidas es fundamental para conseguir una correcta precisión de las predicciones.

La formulación matemática del modelo de evolución de la atmósfera se basa en un sistema de ecuaciones diferenciales parciales, que debido a su gran tamaño no tiene una solución analítica. Por ello, será necesario utilizar herramientas numéricas para resolver el sistema. La solución al sistema de ecuaciones diferenciales, estará resuelta en tiempo y en espacio para un conjunto de valores concretos. Se hallarán las condiciones climáticas de un conjunto de puntos espaciales definidos por una **rejilla**, cuyos puntos pueden estar separados por distancias del orden de kilómetros. Este parámetro será referido como la resolución espacial del NWP.

Por otra parte, la distancia en el tiempo entre las predicciones, se denominará resolución temporal, que será del orden de las horas. La resolución temporal del NWP, impondrá su

escala en el tiempo a los modelos de predicción de potencia que utilicen estas medidas. Por esa razón suministrarán información sobre la previsión de potencia media durante determinado periodo, sin prestar atención a las fluctuaciones.

La predicción de viento obtenida con el modelo NWP, no es aplicable directamente al parque eólico porque su resolución espacial no abarca los efectos locales de la ubicación. Consecuentemente, será necesario extrapolar los resultados, tomando en cuenta la rugosidad del terreno, los obstáculos colindantes, ríos y lagos que puedan introducir cambios en la temperatura superficial, y por lo tanto produzcan particularidades en los vientos locales. Ese proceso se denomina "downscaling". Se han desarrollado metodologías simples que tienen en cuenta solo el efecto del terreno, y otros modelos más complejos de la dinámica de flujo.

También será necesario adecuar la velocidad del viento a la altura del rotor del aerogenerador. El efecto de la tierra hace que las capas más bajas de aire sufran una disminución de velocidad que depende del tipo de terreno. Una de las aproximaciones empíricas clásicas es:

Ecuación 3.6
$$v(z) = v(z_{ref}) \left(\frac{z}{z_{ref}} \right)^\alpha$$

En esta ecuación, se adapta el viento que se encuentra a una altura Z_{ref} , a una nueva altura Z , teniendo en cuenta las características del terreno, dadas por α , que valdrá, por ejemplo, 0.10 en el caso de ser liso o 0,32 en el caso de ser una zona suburbana.

3.3.1 Modelado del proceso de conversión de energía

La curva característica de potencia de un aerogenerador es una descripción que debe entenderse como teórica, ya que el fabricante la ha obtenido mediante experimentos muy controlados en túneles de viento. Cuando los aerogeneradores son colocados juntos en un parque eólico, la curva característica no puede utilizarse para modelar la conversión, y será por tanto, necesario realizar una estimación de la curva de potencia del parque eólico, que cubra todos los aspectos que contribuyen al proceso [6].

Una primera aproximación, sería considerar la curva característica de cada uno de los aerogeneradores del parque y combinarlas. Sin embargo la disposición de unas turbinas respecto a otras afecta al resultado total de la función, ya que existe un efecto denominado "shadowing" o efecto estela.

Este efecto se basa en el hecho de que los aerogeneradores extraen energía del flujo de aire. Como consecuencia, el viento que ha atravesado un aerogenerador tiene menos velocidad, y por lo tanto produce menos energía. Este efecto se intenta evitar eligiendo una disposición determinada de los aerogeneradores en el parque, pero existen restricciones como la disponibilidad de terreno suficiente, o el coste de conectar aerogeneradores muy dispersos entre sí. Por estas razones, la curva de potencia de un parque eólico dependerá tanto de la velocidad, como de la dirección del viento en el parque. Además existen otros muchos factores que condicionan la curva de potencia. En primer lugar está la evolución de las máquinas del parque eólico, que se irán añadiendo, eliminando y manteniendo con el tiempo, provocando efectos en la curva de potencia. Con el paso del tiempo, las turbinas y los generadores eléctricos también modifican su comportamiento. Otro factor es la evolución de los obstáculos anexos al parque, que irán sufriendo modificaciones, que en el caso de la vegetación, pueden ser periódicas.

En definitiva, la curva de potencia del parque eólico también dependerá del tiempo, y tendrá que ser modificada constantemente con nuevos datos que reflejen cambios en el parque. En la siguiente gráfica se puede observar la curva de potencia de un parque eólico de Dinamarca, durante un periodo de estudio de 2000 horas. Se puede observar la variabilidad de potencias medidas, ante la misma velocidad de viento.

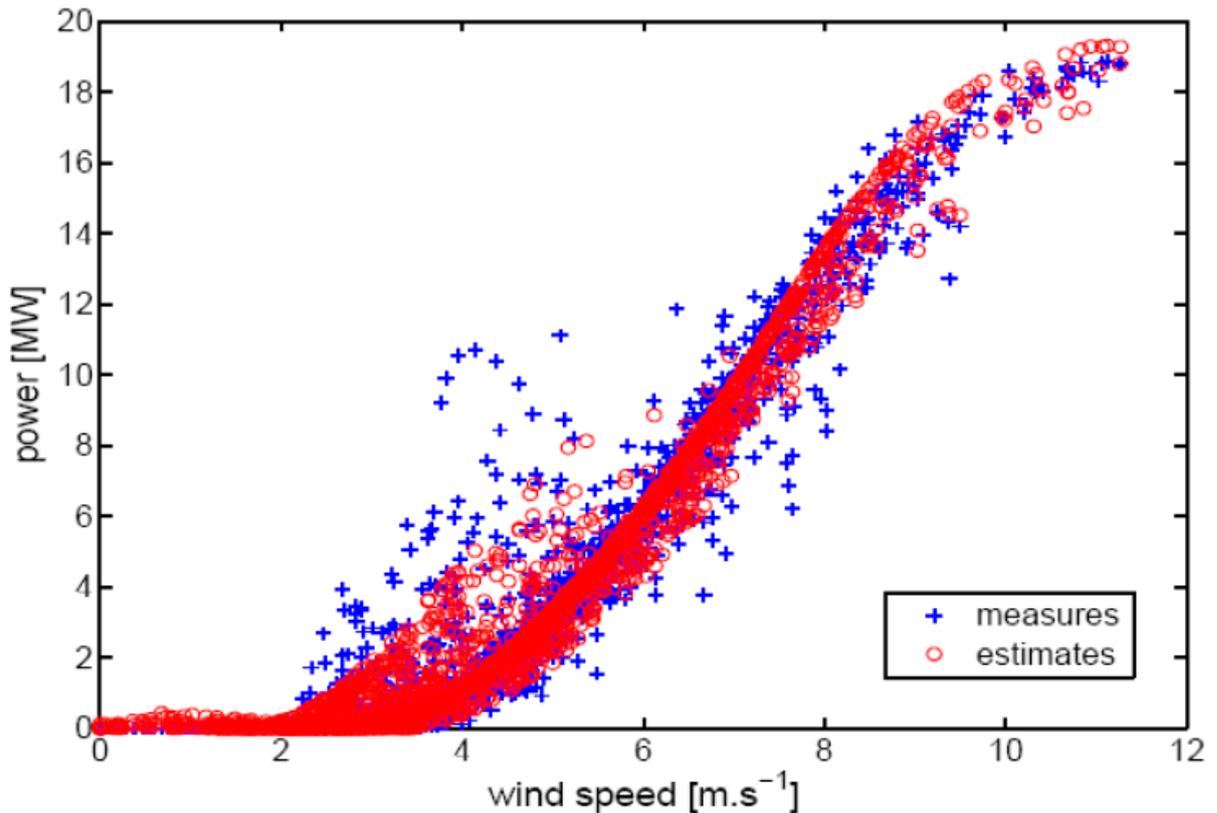


Figura 3.5: Curva de potencia estimada y medida de un parque eólica de 21MW en Dinamarca en un periodo de 2000 horas.
Fuente: UCLM

3.3.2 Importancia de las predicciones para el Operador del Sistema Eléctrico

El operador de un sistema eléctrico debe mantener un equilibrio dinámico continuo entre la energía que se genera y la que se consume, ya que la energía eléctrica no se puede almacenar de forma masiva. Por tanto, se debe hacer una planificación diaria, y con antelación suficiente, de la energía eléctrica que se va a generar y el tipo de centrales que participarán en ese mix de energía, determinando además la reserva de generación necesaria para mitigar los posibles desvíos.

Hace apenas una década la potencia eólica instalada no era muy elevada, insignificante en comparación con la potencia total demandada en el sistema, de modo que la energía eólica generada se consideraba como una demanda negativa, casi despreciable para el sistema. Así, se programaba la generación con centrales convencionales de tanta energía eléctrica como fuese necesaria para cubrir la demanda prevista.

Sin embargo, en algunos países la penetración eólica en el sistema en términos de energía ha alcanzado valores entre el 15% y el 20%. Conforme ha ido aumentando la potencia eólica instalada, la consideración de la eólica como una ligera perturbación negativa en la demanda ha adquirido valores cada vez más significativos, que afectan de forma decisiva en la curva de demanda de energía eléctrica prevista, alejándola de la demanda real [11].

En aquellos países en los que la potencia eólica instalada ha adquirido valores importantes, se ha optado por desligar la aportación eólica de la previsión de demanda, y se ha hecho necesaria por tanto una predicción específica para conocer la potencia eólica que habrá en el sistema a corto plazo.

La predicción eólica se hace imprescindible para los operadores del sistema eléctrico por los siguientes motivos:

- Gestión de congestiones. La predicción eólica ayuda a identificar posibles cuellos de botella en elementos de la red en la evacuación de este tipo de energía, y programar las centrales que ayuden a descongestionarlos. Estas congestiones pueden producirse tanto en las líneas de un sistema eléctrico como en las interconexiones entre sistemas de distintos países [12].
- Identificación de posibles inestabilidades en la red, como desconexiones masivas inadmisibles debidas a huecos de tensión. · Estimación de reservas. Dada la variabilidad del viento, la generación eólica no ofrece garantía de potencia, lo que obliga a disponer de una reserva de potencia adicional de otras fuentes de generación para hacer frente a una posible ausencia de producción eólica.
- Planificación de intercambios internacionales con sistemas eléctricos vecinos, teniendo en cuenta la disponibilidad o exceso de generación eólica que no se espera consumir.

Por todo ello, se puede concluir que no toda la generación eólica se puede integrar en la red. La producción eólica estará limitada por las posibles congestiones o sobrecargas en las líneas provocadas por la evacuación de la generación eólica, la estabilidad del sistema frente a posibles desconexiones masivas ante perturbaciones como los huecos de tensión, la viabilidad en los balances de potencia para cubrir la demanda teniendo en cuenta las restricciones técnicas de las unidades gestionables, y los excedentes de generación eólica no integrables en el sistema.

El hecho de que el operador del sistema disponga de un sistema de predicción de la generación eólica que permita estimar la energía horaria que se generará en los parques eólicos durante las siguientes horas permite disminuir los desvíos en los programas de generación y reserva y minimizar el impacto en la operación, haciendo que ésta sea más fiable y segura.

La predicción ayuda por tanto a avanzar hacia un mayor grado de penetración de la generación eólica en el sistema eléctrico, que sea compatible con la seguridad de operación y que permita integrar la mayor cantidad de energía renovable, eólica en este caso, en el sistema. Los avances en los modelos de predicción contribuyen así a lograr una mayor penetración de la energía eólica en el balance energético.

3.4 Bibliografía de los modelos de predicción a corto plazo de la producción eléctrica de origen eólico.

Este apartado presenta una revisión bibliográfica de los modelos de predicción de producción eléctrica, a corto plazo, en parques eólicos que han sido publicados en la literatura internacional. Se ha incluido, además, un apartado de criterios de evaluación de modelos de predicción, señalando los indicadores estadísticos escogidos para la evaluación de los modelos propuestos en la literatura especializada.

3.4.1 Evaluación de modelos de predicción.

Como se ha indicado anteriormente, en este apartado se comentan los indicadores estadísticos más usuales en la evaluación de modelos de predicción de producción eléctrica en parques eólicos así como el modelo de referencia. Para cualquier tarea de predicción con datos cuantitativos son varias las etapas que se deben seguir [13], [14]. De forma resumida estas etapas son las indicadas a continuación.

1. *Definición del problema:* Incluye la comprensión de cómo se usarán las predicciones, para qué se usarán, y quién las usará. En definitiva, en este primer paso se pretende recabar la máxima información de los usuarios, suministradores de datos y expertos en el tema, para poder ofrecer a los usuarios las predicciones con las características que mejor se adapten a sus necesidades.
2. *Recogida de información:* Es necesario recoger datos históricos de las variables de interés, incluyendo la variable a predecir, así como de todas las posibles variables explicativas accesibles. La información puede ser cuantitativa (datos numéricos) o cualitativa (opiniones de expertos).
3. *Análisis preliminar:* El estudio de los valores estadísticos descriptivos (media, varianza, correlaciones, etc.) puede ayudar en la selección de los modelos más adecuados, reconocer outliers, seleccionar las variables explicativas de mayor peso, etc.
4. *Elección y ajuste de modelos:* Un modelo de predicción esencialmente consiste en un sistema de ecuaciones (lineales o no) que relacionan los valores futuros de la variable a predecir con los valores presentes y pasados de la propia variable y de las variables explicativas. El ajuste del modelo se basa en la adecuación de las características o

parámetros del modelo, de forma que se minimizan los errores de predicción para el conjunto de datos con los que se ha construido. Este error será tanto menor cuanto mejor se haya realizado la elección del modelo, es decir, cuanto más idóneo sea el modelo a la hora de representar las relaciones reales entre la variable a predecir y las variables explicativas.

5. *Evaluación de modelos:* El funcionamiento de un modelo debe ser evaluado, obviamente no con los datos utilizados en su ajuste (para algunos modelos, como los basados en las redes neuronales artificiales, con los datos usados en su aprendizaje o entrenamiento), sino con otro conjunto de valores (valores de testeo) de las variables explicativas no utilizado en el ajuste del modelo. Esta prueba permitirá la comparación de los resultados (valores de predicción) entre diferentes modelos y la selección del modelo que arroje los menores errores de predicción.
6. *Uso del modelo:* Una vez comprobado su funcionamiento, el modelo puede ser usado para realizar las predicciones.

La quinta etapa es la más importante cuando tratamos de seleccionar definitivamente un modelo de predicción entre varios posibles. Se puede facilitar esta selección de modelos mediante un análisis de los valores alcanzados por unos indicadores estadísticos sobre las predicciones del modelo, estudiando así la bondad de las mismas.

Modelo de referencia.

En el campo de la predicción, se han definido algunos modelos sencillos que sirven como referencia a la hora de evaluar la bondad de los nuevos modelos de predicción desarrollados. Estos modelos de referencia están basados en modelos sencillos de series temporales.

Uno de los modelos de referencia más utilizados es el modelo de Persistencia. Según este modelo las predicciones de potencia a futuro, para cualquier horizonte, coinciden con el valor actual de la variable, en este caso la potencia eólica:

$$\text{Ecuación 3.7} \quad \hat{P}_{t+h|t} = P_t$$

Donde $\hat{P}_{t+h|t}$ es la predicción para el horizonte de tiempo $t+h$, calculada en el instante actual t , y P_t es la medida actual de potencia registrada en el parque o la región de estudio.

Este modelo de predicción para parques solamente tiene un buen funcionamiento para predicciones hasta un horizonte muy reducido, de no más de 2 ó 3 horas, aunque si se trata de predicción regional, puede llegar a dar buenos resultados para horizontes algo mayores, hasta 4 ó 6 horas, ya que los cambios atmosféricos en una región tienen un orden temporal bastante superior al de los cambios que afectan a un parque individual.

El modelo de persistencia es un caso concreto del modelo de media móvil de las últimas n observaciones, con $n=1$

Ecuación 3.8
$$\hat{P}_{t+h|t} = \frac{1}{n} \sum_{\tau=0}^{n-1} P_{t-\tau}$$

siendo $\hat{P}_{t+h|t}$ la medida de potencia en el instante $t+\tau$, de antigüedad τ .

Cuando el orden del modelo de media móvil tiende a infinito, entonces tenemos la media global o incondicional de todo el histórico de potencias eólicas registradas en el parque o región, también llamada media climática, lo que sería un buen modelo de predicción a muy largo plazo:

Ecuación 3.9
$$\hat{P}_{t+h|t} = \bar{P}_t$$

Fruto de combinar la bondad de las predicciones del modelo de persistencia para el muy corto plazo, y la relativa bondad de las predicciones de un modelo de media global de potencia para predicciones a largo plazo, nace un nuevo modelo de referencia, propuesto en [36], que resulta de una ponderación de ambos métodos, cuyos coeficientes de ponderación dependen del horizonte de predicción:

Ecuación 3.10
$$\hat{P}_{t+h|t} = a_h P_t + (1 - a_h) \bar{P}_t$$

donde a_h es el factor de ponderación que habría que estimar, con valores entre 0 y 1 dependiendo del horizonte de predicción, y que tomará valores cercanos a la unidad para horizontes de predicción muy cortos, dando mucho peso al modelo de persistencia, y valores cercanos a cero para horizontes de predicción muy elevados, en los que la potencia esperada se aproximará más a la media de potencia registrada históricamente.

Aunque el nuevo modelo de referencia propuesto en la ecuación 10 es más elaborado y proporciona mejores resultados que el modelo de persistencia, en la práctica el modelo de

referencia más utilizado sigue siendo el modelo de persistencia, debido a su sencillez y a que no requiere la estimación de parámetro alguno.

3.4.2 Familias de modelos de predicción de la producción eléctrica de origen eólico en el corto plazo.

La necesidad, por parte de generadores y operadores de los sistemas eléctricos, de disponer de herramientas de predicción de la energía eléctrica producida de origen eólico que proporcionen el mínimo error posible, se recoge ya en los primeros trabajos publicados. La necesidad de modelos de predicción de la generación se justifica, en estos primeros trabajos, sobre los beneficios económicos que aporta un sistema de predicción, especialmente para los casos de una importante penetración de los sistemas de generación eléctrica de origen eólico. Se entiende esta importante penetración como un porcentaje significativo de potencia instalada en parques eólicos frente a centrales eléctricas convencionales.

El primer modelo auténtico de predicción de velocidad del viento, específico para ser usado en la estimación de la producción de energía eléctrica, es el presentado en [Bossanyi85], donde se propone el uso de un filtro Kalman para predicciones de la velocidad media del viento para los próximos minutos (hasta una hora). Los resultados son relativamente buenos para horizontes de predicción por debajo de los 10 minutos, pero ya no tanto para un horizonte de una hora, donde claramente el autor apunta que el método no resulta ser el más adecuado para la predicción de la velocidad media horaria.

Tras estos primeros trabajos publicados, son dos los tipos de modelos de predicción propuestos en la literatura internacional. Por una parte se desarrollan modelos que utilizan como datos de entrada valores pasados, bien de la propia serie temporal de la variable a predecir (velocidad del viento o energía producida), o bien de otras variables explicativas que pueden contribuir a reducir los errores de predicción. Denominaremos a estos modelos como pertenecientes a la familia de series temporales. Frente a estos, se desarrollan otros modelos que incorporan como entradas, además de las comentadas para modelos de series temporales, los valores de predicción para variables meteorológicas obtenidos por los programas de predicción numérica existentes en institutos meteorológicos (modelos atmosféricos).

Algunos de los trabajos publicados se limitan a la predicción de la velocidad media horaria del viento. En otros trabajos se ofrece también la predicción de la potencia eléctrica media horaria producida. El cálculo de esta última se realiza por medio de la relación entre potencia eléctrica producida y velocidad del viento, obtenida de forma empírica para el propio parque para el que se realiza la predicción, o utilizando la ofrecida por el fabricante del aerogenerador (curva de potencia del fabricante).

En la literatura internacional pueden encontrarse un par de interesantes revisiones bibliográficas sobre el tema. Una buena fuente sobre estado actual de los modelos de previsión a corto plazo la constituyen [15] y [16].

Otra fuente interesante es la editorial Elsevier (editorial prestigiosa de libros y publicaciones científicas), en ella se han publicado numerosos artículos relacionados con el tema. Entre ellos cabe destacar:

- *Wind power usage and prediction prospects in Lithuania* [17]: En este artículo se analiza la situación actual y las perspectivas futuras en cuanto a la potencia eólica instalada en Lituania. Se comentan las características del sistema eléctrico y las cuestiones relacionadas con la integración de la energía eólica en las redes eléctricas. El objetivo de este trabajo es señalar la importancia de la predicción eólica, presentando una reseña de los métodos de predicción de viento, y seleccionando los más adecuados para las condiciones de dicho país.
- *A review on the young history of the wind power short-term prediction* [18]: Este artículo señala los modelos más representativos y herramientas desarrolladas a lo largo de la historia en la predicción eólica a corto plazo. Diferenciando la evolución antes de los años 90, en los años 90 y desde el año 2000. Concluye que es necesario una mejora de la precisión de los modelos y las herramientas existentes.
- *A review on the forecasting of wind speed and generated power* [19]: Este artículo como muchos otros, clasifica los modelos de predicción en dos categorías: el método físico y el método estadístico (como el modelo ARMA). Establece que el método físico tiene ventajas en la predicción a largo plazo, mientras que el estadístico va bien en la predicción a corto plazo. También aclara que esta clasificación no es absoluta ya que

en la práctica ambos modelos se utilizan de forma simultánea. Se comentan los nuevos métodos basados en la inteligencia artificial, como la red neuronal (ANN) y los modelos de lógica difusa.

- *Comparison of two new short-term wind-power forecasting systems* [20]: En este artículo clasifican los modelos de predicción en dos grupos: un primer grupo que sólo emplea los datos de series de tiempo y predice los valores futuros, teniendo en cuenta la historia pasada, y un segundo grupo que utiliza los valores de la predicción numérica del tiempo. Los modelos del primer grupo utilizan el método estadístico. Comenta los modelos de predicción de energía eólica cuyas variables de entrada han sido aportadas por los modelos de predicción numérica del tiempo tales como el modelo danés Prediktor y el modelo del WPPT, el modelo español Sipreolico y el modelo LocalPred CENER, el modelo alemán Previento y el modelo de ISET de entornos colaborativos, los modelos franceses Armines AWPPS, el modelo griego Universidad Técnica Nacional de Atenas (NTUA) y el modelo de la Universidad Aristóteles de Tesalónica (AUTH), y el modelo norteamericano eWind.

Modelos de predicción basados en series temporales de viento o en series de energía eléctrica generada.

En la tabla 3.2 se presenta resumidamente las características más relevantes de los modelos de predicción, pertenecientes a esta primera familia basada en series temporales, propuestas en la literatura internacional. En dicha tabla se indica la variable que predicen (velocidad media horaria o potencia eléctrica media horaria), el tipo de modelo, el horizonte de predicción máximo, los criterios de evaluación y la mejora obtenida con respecto al modelo persistente (si lo indican).

Tabla 3.1: Resumen de características de modelos de predicción de la primera familia.
Fuente: Tesis Doctoral, Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos

Referencia	Variable de predicción	Tipo modelo	Horizonte	Criterio evaluación	Mejora respecto a persistente
43	potencia eléctrica	Red neuronal	2 horas	RMSE	13.5%
44	velocidad del viento	ARIMA	6 horas	---	---
45	velocidad del viento	ARIMA	30 min.	---	---
46	velocidad del viento	Red neuronal	2 horas	MAE	27%
47	velocidad del viento	ARIMA, Red neuronal, neuro-difuso	1 hora	RMSE	4.9%
48	velocidad del viento, potencia eléctrica	neuro-difuso	10 horas	---	---
49	velocidad del viento	neuro-difuso + Fourier	1 hora	RMSE	9%
50	velocidad del viento	ARIMA	1 hora	RMSE	2 - 5%
51	velocidad del viento	ARIMA	3 horas	---	---
52	energía eléctrica	Fuzzy	24 horas	RMSE	14.3%
53	potencia eléctrica	Regresión	6 horas	RMSE	14.1%
54	velocidad del viento	Fuzzy + GA	4 horas	RMSE	18.2%
55	velocidad del viento	Red neuronal	24 horas	MAE	---
56	velocidad del viento	ARIMA	10 horas	RMSE	12 - 20%
57	velocidad del viento	Red MLP	1 hora	---	---
58	velocidad del viento	neuro-difuso	2.5 min.	MAE	87%
59	potencia eléctrica	“gris”	1 hora	ME	12%

Modelos de predicción basados en modelos atmosféricos.

En la tabla 3.2 se presentan resumidamente las características más relevantes de los modelos de predicción pertenecientes a esta segunda familia (basada en predicciones de modelos atmosféricos). En dicha tabla se recogen los modelos utilizados, el modelo atmosférico que proporciona las predicciones de variables meteorológicas como la velocidad y dirección de viento, temperatura, etc., y las características esenciales de las técnicas usadas en el modelo de predicción de la producción eléctrica en un parque eólico. También figuran en la tabla los horizontes máximos de predicción de cada modelo, el criterio de evaluación seleccionado para la determinación de los errores de predicción, así como la mejora con respecto al modelo persistente (mejora correspondiente al horizonte máximo considerado, en caso de que el modelo estudiado haya presentado algún ejemplo de aplicación).

Tabla 3.2: Resumen de características de modelos de predicción de la segunda familia. Fuente: Tesis Doctoral, Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos.

Referencia	Modelo de predicción	Modelo atmosférico	Horizonte	Criterio evaluación	Mejora respecto a persistente
60	MOS - WASP	HIRLAM	36 horas	---	---
61	Estadístico	HIRLAM	24 horas	RMSE	30%
62	Físico+MOS+WASP	HIRLAM	36 horas	RMSE	48%
63	Físico+MOS	Deutschland	48 horas	RMSE	---
64	Físico+MOS+correlación	Lokalmodel	48 horas	RMSE	---
65	Estadístico	HIRLAM	48 horas	---	---
66	Neuronal	MM5	24 horas	RMSE	35.3%
67	Neuronal	MM5	2 horas	RMSE	14 – 37%
68	Estadístico	HIRLAM	36 horas	MSE	---
69	Neuronal + fuzzy	HIRLAM	41 horas	RMSE	42%

Conclusiones.

Son varias las conclusiones que se pueden extraer de la revisión bibliográfica sobre la predicción de la producción eléctrica en un parque eólico y que son comentadas a continuación.

1. Los modelos de la primera familia (modelos basados en series temporales) presentan mejores resultados que los modelos de la segunda familia (los basados en valores de predicción de variables meteorológicas obtenidos de modelos atmosféricos) para horizontes de predicción relativamente bajos, con un límite entre las 3 y las 6 horas. Así, en [21] un modelo auto-regresivo (por tanto de la primera familia) presenta menores errores de predicción que los modelos de la segunda familia basados en redes neuronales para horizontes de predicción por debajo de las 6 horas. En general, los modelos publicados parecen “focalizados” para un intervalo específico de horizonte de predicción. Así, los modelos de la primera familia están diseñados para realizar las predicciones de potencias eléctricas en parques eólicos en el muy corto plazo, mientras que los modelos de la segunda familia están más orientados a realizar la predicción para el día siguiente (marcando su aplicación para la realización de ofertas de venta en el mercado eléctrico, así como para otras necesidades

relativas a la operación del Sistema Eléctrico). Ningún sistema de predicción de la producción eléctrica combina ambas características.

2. En los modelos de predicción de la primera familia no existe un criterio de evaluación de error común, puesto que utilizan tanto el error medio (ME), como el error absoluto medio (MAE) o la raíz del error medio cuadrático (RMSE). Por el contrario los modelos de predicción publicados y pertenecientes a la segunda familia, utilizan de forma generalizada el indicador RMSE, como criterio de evaluación del error en la predicción.
3. A pesar de haberse propuesto un modelo de referencia en [22], para obtener los resultados de predicción de potencias eléctricas con los que comparar los obtenidos con cualquier otro modelo propuesto, se utiliza como modelo de referencia exclusivamente el modelo persistente, independientemente del horizonte de predicción.
4. Los errores de predicción dependen del horizonte de predicción: cuanto mayor es el horizonte de predicción mayor es el error. Sin embargo, en la comparación de modelos propuestos con el modelo persistente, la mejora de la predicción con cualquier modelo propuesto crece con el horizonte de predicción.
5. El nivel de detalle que aparece en las publicaciones sobre modelos de la primera familia es muy superior al de los modelos de la segunda familia. Es más, mientras que para los modelos de la primera familia se presentan de forma generalizada los resultados y errores obtenidos con la aplicación del modelo, para los modelos de la segunda familia son casi excepcionales las publicaciones que lo hacen, quedándose la mayoría en una mera descripción del modelo propuesto.
6. Los resultados publicados y obtenidos con los distintos modelos son muy dispares. Igualmente, puede afirmarse que no es posible alcanzar resultados (de predicción de producción eléctrica) equiparables de un lugar geográfico (para el que se realiza la predicción) a otro. Ello es debido esencialmente a que las condiciones locales de viento dependen altamente de la orografía del lugar donde se sitúa el parque eólico, y también de la situación de cada uno de los aerogeneradores que lo componen [23], de tal forma que resulta casi imposible alcanzar un nivel de error similar con el mismo modelo de predicción para todos los parques eólicos. Así, no es posible obtener un nivel de error de predicción similar para un parque eólico situado en un terreno llano, que para otro parque situado en un terreno significativamente montañoso.

7. Los errores de predicción se pueden reducir como consecuencia de la agregación (predicción para un conjunto de parques eólicos): se obtiene menor error en la predicción a nivel regional o nacional para un conjunto de parques eólicos que en la predicción de un único parque [24].
8. Para el desarrollo de modelos de predicción (de producción eléctrica) de la segunda familia, se han utilizado diferentes modelos atmosféricos que casi siempre han sido desarrollados, mantenidos y ejecutados por institutos meteorológicos nacionales. En este sentido, una buena parte de los diseñadores de nuevos modelos de predicción de la producción eléctrica en un parque eólico vienen a ser, en cierta forma, "clientes" de los institutos meteorológicos (o de empresas que a su vez son clientes de dichos institutos).
9. La reducción de los errores de predicción de producción eléctrica para modelos de la segunda familia está ligada a la reducción de los errores de predicción de las variables meteorológicas de los modelos atmosféricos. Esta reducción de errores (mejora de las predicciones de potencia eléctrica) se consigue fundamentalmente aumentando la resolución de dichos modelos atmosféricos.
10. Las predicciones de variables atmosféricas de interés para la predicción de la producción eléctrica en un parque eólico son, esencialmente, la velocidad y dirección del viento, utilizándose excepcionalmente otras (temperatura, densidad del aire, humedad, etc.).
11. La adaptación (si ésta es posible) de la mayor parte de los modelos publicados, a otros parques eólicos, debe ser realizada por un experto: la correcta modelización física, la adecuación de los parámetros, el ajuste de "ventanas temporales", etc., requiere de la participación de un experto.

3.5 Error de predicción de la potencia eólica

En este apartado se definirán una serie de técnicas que se considerarán a la hora de evaluar el error cometido por las predicciones de potencia eólica. Al comparar distintos métodos de predicción es necesario establecer una serie de métodos estándar que permitan comparar los resultados. Por ello nos apoyaremos en los resultados publicados por ANEMOS, un proyecto de investigación y desarrollo de la UE que pretende desarrollar una nueva generación de sistemas de predicción de potencia eólica que permita la integración a gran escala de los parques eólicos en la red de electricidad. Este grupo, donde ha participado un

importante consorcio de compañías europeas (por ejemplo, REE, CENER, EDF ...), ha publicado diversos documentos sobre este tema, y se tomará como referencia su sistema de evaluación, así como su notación.

Las técnicas de evaluación del error, están agrupadas según dos tendencias: La evaluación orientada a la medida de parámetros de error, y a la evolución orientada al estudio de las distribuciones del error. Estas dos orientaciones se complementan entre si y permiten obtener una visión más completa del error [26].

3.5.1 Definición del error de predicción

Se definirá el error de predicción como:

$$\text{Ecuación 3.11} \quad e_{t+k/t} = P_{t+k} - \hat{P}_{t+k/t}$$

Esta ecuación define el error de una predicción realizada en el instante t , para el intervalo $t+k$. Siempre que se defina una predicción, se tendrá que especificar su horizonte de predicción, es decir, cuánto tiempo separa el momento donde se efectúa la predicción, al momento que se pretende predecir.

La razón de especificar siempre el horizonte de predicción se debe a que la precisión de las predicciones depende de él.

A menudo es conveniente normalizar el error de predicción para poder comparar predicciones de distintas instalaciones. Se definirá el error de predicción normalizado como:

$$\text{Ecuación 3.12} \quad \epsilon_{t+k/t} = \frac{(P_{t+k} - \hat{P}_{t+k/t})}{P_{inst}}$$

En la ecuación 12 se normaliza con la potencia instalada en el parque eólico.

Cualquier tipo de error, puede ser descompuesto es una parte sistemática $\mu_{t+k/t}^e$ y otra parte aleatoria $\zeta_{t+k/t}^e$

Ecuación 3.13
$$e_{t+k/t} = \mu_{t+k/t}^e + \xi_{t+k/t}^e$$

En esta ecuación, el primer sumando es una constante, y el segundo es una variable aleatoria de media cero.

Idealmente, si se tratara de un sistema de predicción perfecto, el error sistemático sería cero y la parte aleatoria sería ruido blanco (distribución normal de media cero).

Es importante a la hora de medir el error de predicción, tener precaución de los datos que se tienen en cuenta. La primera precaución consiste en asegurar un mínimo de calidad de las medidas, no aceptando incluir en los cálculos datos que son sospechosos de deberse a errores (por ejemplo aquellas medidas que están fuera de rango, o que repiten su valor en dos instantes consecutivos, sin que estos valores sean 0 o la P_n). Si los errores introducidos del sistema son aislados y aleatorios, su efecto en las medidas finales no tendrá ninguna consecuencia importante. Sin embargo, en caso de deberse a un error sistemático, las conclusiones sobre el error de predicción quedan viciadas.

Otro factor a tener en cuenta es que se deben incluir en los cálculos datos con la suficiente variedad (días con distintos perfiles de producción eólica), como para obtener una conclusión global del sistema de predicción. Para ello debe analizarse un periodo de tiempo significativo.

Por último, cabe destacar que las mismas series de datos no pueden utilizarse para ajustar el modelo de predicción y para luego evaluarlo. Este tipo de actuaciones conducen a unas conclusiones excesivamente optimistas. Por ello los datos deben ser divididos en dos conjuntos, uno de entrenamiento para ajustar la función de predicción y otro conjunto de prueba, para evaluar los resultados finales.

3.5.2 Evaluación del error orientada a la medida de parámetros

En esta sección se describirán algunos parámetros que miden diversas cualidades del error.

La medida de sesgo BIAS, estima el error medio sobre un periodo de evaluación, y se calcula para cada horizonte de predicción distinto. Se define como:

$$BIAS(k) = \hat{\mu}_k^e = \frac{1}{N_T} \sum_{t=1}^{N_T} e_{t+k/t}$$

Ecuación 3.14

En las ecuaciones definidas en este apartado, N_t es el número de muestras de error que se utilizan en el cálculo. De la misma manera, se define la BIAS normalizada como:

$$NBIAS(k) = \frac{1}{N_T} \sum_{t=1}^{N_T} \epsilon_{t+k/t}$$

Ecuación 3.15

De esta manera, todas las medidas de error que se expresen de ahora en adelante, tendrán su versión normalizada al utilizar como datos en los cálculos los errores normalizados y añadiendo una N al nombre del parámetro definido (ej. BIAS a NBIAS).

La BIAS indica si un método de predicción, tiende a sobreestimar o subestimar la variable de predicción. Cuando la BIAS se calcula utilizando todos los datos de error, ofrece unas conclusiones muy rudimentarias, ya que normalmente los métodos de predicción mantienen un bajo nivel de BIAS debido a la aplicación de técnicas MOS. Sin embargo, si se calcula la BIAS sobre subconjuntos de errores, agrupados según distintas características (distintas condiciones climáticas, o distinto valor de predicción), se observan sesgos que estaban ocultos bajo el análisis global donde se equilibraban los errores negativos y positivos.

En definitiva, si un método de predicción obtiene un resultado BIAS igual a 0, evaluando el conjunto de las muestras de error, es poco probable que el sistema esté ofreciendo unas predicciones perfectas, por lo que habría que realizar un análisis más minucioso del error.

El error cuadrático medio, o MSE(k) ("Mean Square Error"), será una medida del error que indicará la contribución de todos los errores tanto positivos como negativos. Se calcula como:

$$MSE(k) = \frac{1}{N_T} \sum_{t=1}^{N_T} (e_{t+k/t})^2$$

Ecuación 3.16

La raíz del error cuadrático medio se expresa como:

$$RMSE(k) = \sqrt{MSE(k)} = \sqrt{\frac{1}{N_T} \sum_{t=1}^{N_T} (e_{t+k/t})^2}$$

Ecuación 3.17

Otra medida común del error, es la media del error absoluto, MAE(k) ("Mean Absolute Error"), definida como:

$$MAE(k) = \frac{1}{N_T} \sum_{t=1}^{N_T} |e_{t+k/t}|$$

Ecuación 3.18

La elección de RMSE o MAE como criterio de evaluación principal del error de predicción, depende de la sensibilidad al error del usuario final. Esa sensibilidad es representada por la función de coste del error. El uso de RMSE implica la consideración de una función de coste cuadrática, mientras que MAE sería más apropiado para usar una función de coste lineal.

Si el método de predicción es evaluado mediante RMSE, se espera que el método de predicción haya sido entrenado para producir predicciones de MSE mínima.

En caso de que no se tenga constancia de la función de coste que se utilizó para minimizar el error del modelo de predicción, es mejor no confiar sólo en RMSE, y ofrecer el resultado de ambos métodos.

Una posible alternativa al uso de RMSE, es considerar la estimación de la desviación estándar del error, SDE(k) ("Standard Deviation of the Errors"), definida según:

$$SDE(k) = \hat{\sigma}_k^e = \sqrt{\frac{1}{N_T - 1} \sum_{t=1}^{N_T} (e_{t+k/t} - \hat{\mu}_k^e)^2}$$

Ecuación 3.19

SDE es un criterio de evaluación que mide la parte aleatoria del error. La parte sistemática y aleatoria del error contribuyen a RMSE y MAE. Sin embargo MAE está asociado

al primer orden de la distribución del error de predicción, mientras que RMSE y SDE están asociados al segundo orden (la varianza), aunque no tiene una interpretación directa. Para estas dos medidas, las medidas que presentan un gran error, producen un gran efecto, por lo que en caso de no tener confianza en la calidad de las medidas es preferible utilizar MSE.

La comparación entre distintos tipos de predicción puede ser complicada ya que un modelo puede resultar mejor respecto a un criterio de evaluación y peor respecto a otro. Un tipo de comparación que puede resultar de utilidad es mostrar el grado de mejora con respecto al un método de predicción de referencia. Para ello puede utilizarse la siguiente fórmula:

$$Imp_Y^{ref}(k) = \frac{Y^{ref}(k) - Y(k)}{Y^{ref}(k)}$$

Ecuación 3.20

En esta fórmula, Y se sustituirá por el criterio de evaluación deseado (RMSE, MAE,...) y $Y^{ref}(k)$ indicará el resultado del modelo de referencia elegido usando el mismo criterio de evaluación. El resultado perfecto sería 100% que indicaría que el método de predicción evaluado no comete ningún error. También es posible obtener resultados negativos si el modelo de predicción evaluado es mejorado por el modelo de predicción de referencia.

3.5.3 Evaluación del error orientada a la distribución del error

Las medidas introducidas en el apartado anterior permiten resumir la efectividad de un método de predicción con un solo número, por ejemplo, el método A tiene un NMAE del 7% en predicciones realizadas con un horizonte de 1 hora.

Como se ha mencionado en el capítulo anterior, este tipo de medida puede resultar muy pobre a la hora de evaluar realmente la calidad de un método. Por ello, resulta también interesante observar la distribución estadística del error.

La función de densidad de probabilidad de un error, puede ser representada empíricamente mediante el histograma del error.

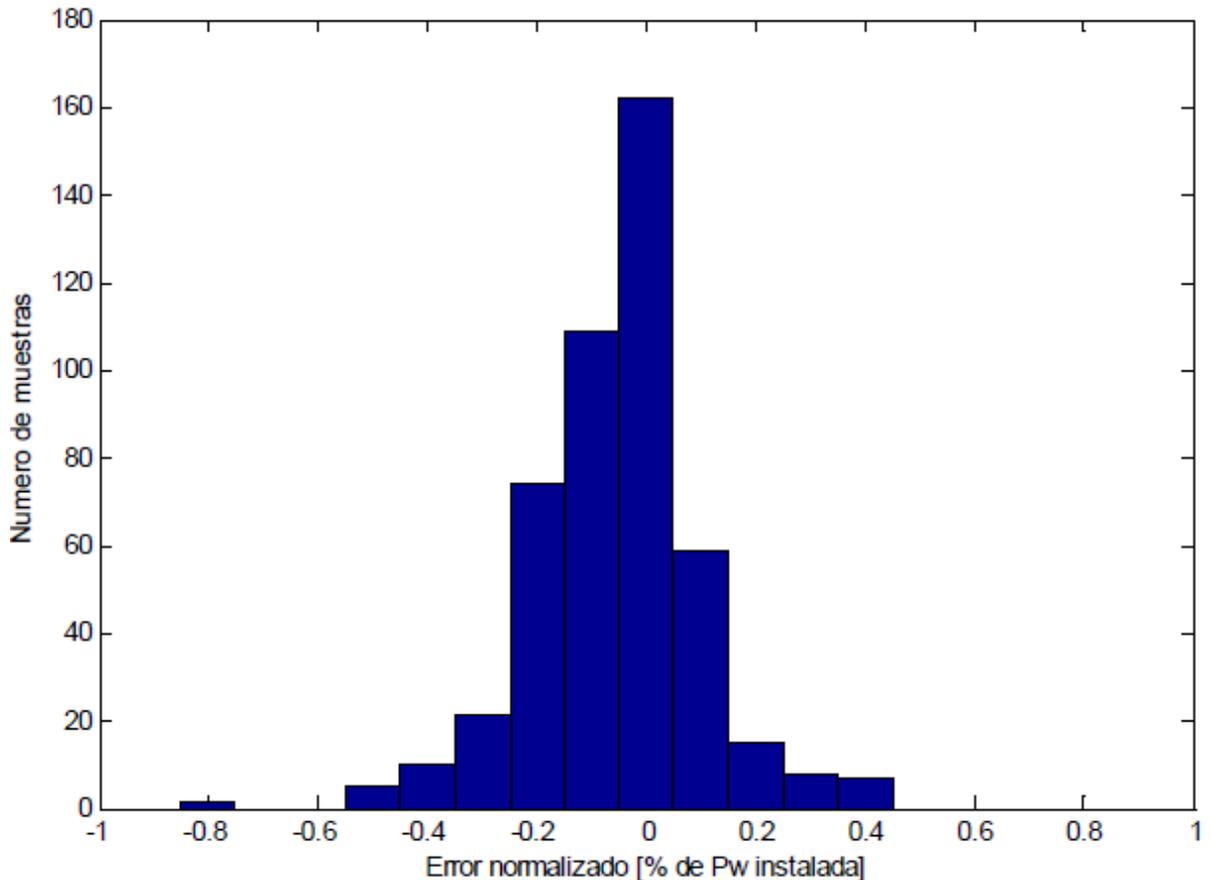


Figura 3.6: Histograma del error normalizado de predicciones de horizonte K=5 para el parque PE3
Fuente: UCLM

En la Figura anterior se observa un ejemplo del histograma del error normalizado de predicción de potencia eólica realizadas con un horizonte de predicción de 5 horas, para el parque PE3. Se ha representado el histograma dividiendo los datos en intervalos del 10% del error.

Observando el histograma, se observa que la función de distribución es asimétrica con una desviación hacia la izquierda, y que casi todos los errores se hallan por debajo del 50%. La evaluación del error orientada a la distribución del error, también llamada como aproximación de Murphy&Winkler por los dos autores que la propusieron, se basa en el estudio de la función de densidad de probabilidad conjunta formada por la predicción y la observación, $f(P, \hat{P})$, para extraer información y evaluar el error. Ya que es bastante difícil estudiar la función de densidad de probabilidad conjunta, se puede optar por el estudio de la función de densidad de probabilidad condicionada $f(P|\hat{P})$, y las funciones de densidad de probabilidad marginales $f(P)$ y $f(\hat{P})$.

Utilizando esta filosofía de trabajo orientada a la distribución, se estudiará la influencia de una variable fijándola (por ejemplo el valor de potencia eólica predicho) y midiendo los momentos estadísticos de los errores asociados.

Se añadirán nuevas medidas para evaluar las funciones de densidad de probabilidad resultantes, además de la BIAS, definida en la ecuación 3.21 para evaluar el error sistemático, y la SDE, definida en la ecuación 3.26 para evaluar la dispersión del error.

El coeficiente de asimetría, v_k^e , indicará la falta de asimetría de la distribución estadística. Si al trazar una vertical por el punto que ocupe el valor esperado del error, ambos lados de la distribución son iguales, se dice que la distribución es simétrica. Este coeficiente indicará hacia qué lado se extiende más la función de densidad de probabilidad.

Se definirá, siguiendo la fórmula de Fischer como:

$$\hat{v}_k^e = \frac{N_T}{(N_T - 1)(N_T - 2)} \sum_{t=1}^{N_T} \left(\frac{e_{t+k/t} - \hat{\mu}_k^e}{\hat{\sigma}_k^e} \right)^3$$

Ecuación 3.21

El exceso de curtosis, $\hat{\kappa}_k^e$, informa sobre la forma de la función de distribución considerada, comparándola con la forma de una distribución normal. El exceso de curtosis de una gaussiana es igual a 0. Se calculará como:

Ecuación 3.22

$$\hat{\kappa}_k^e = \frac{N_T(N_T + 1)}{(N_T - 1)(N_T - 2)(N_T - 3)} \sum_{t=1}^{N_T} \left(\frac{e_{t+k/t} - \hat{\mu}_k^e}{\hat{\sigma}_k^e} \right)^4 - \frac{3(N_T - 1)^2}{(N_T - 2)(N_T - 3)}$$

3.6 Beneficios y penalizaciones de la predicción eólica

La predicción de la generación eólica puede tener importantes repercusiones económicas para el operador del sistema, con una reducción de los costes de operación gracias a la reducción de la necesidad de reserva. Como ejemplo, en [27] se trata un modelo para la determinación óptima de reserva rodante en el sistema teniendo en cuenta la posible generación eólica en los próximos minutos.

Una evaluación sobre el impacto que tiene la precisión de las predicciones sobre los costes de operación del sistema puede encontrarse en [28]. Usando un modelo de evaluación de costes, se estudió el impacto de la precisión de las predicciones eólicas en los costes de operación del sistema, concluyendo que a menor precisión en las predicciones, mayores son los costes de operación por la necesidad de aumentar la reserva rodante. También se comprueba que los beneficios de una compañía con potencia eólica instalada se ven mermados debido a los errores de predicción en la generación eólica, al tener que comprar a otras compañías la energía eléctrica que fue prevista pero que no fue generada.

Así, además de ayudar a la operación del sistema eléctrico, la predicción de potencia eólica se ha convertido en una herramienta de peso para los agentes de mercado o los propietarios de parques eólicos que venden la energía de sus instalaciones en el mercado de electricidad. La explosión en el desarrollo de la energía eólica ha coincidido con la liberalización de los mercados eléctricos en muchos países, y existen penalizaciones económicas frente a los desvíos de generación con respecto de la cantidad de energía pactada en el mercado.

En [29] se presenta el valor de la predicción en términos de ahorro de combustible para una compañía con parques eólicos. El gasto de combustible es comparado con el gasto que se realizaría si se conociese la generación en el parque eólico, usando tanto un modelo simple de persistencia como teniendo en cuenta las predicciones de un modelo atmosférico.

Un estudio para el caso del mercado Danés se presenta en [30], donde se examinó el impacto de la potencia eólica en el mercado Nordpool, simulando el uso de una herramienta de predicción bajo ciertas modificaciones en las reglas del mercado.

En otro estudio descrito en [31] y [32] se utiliza el sistema de predicción de Armines AWPPS sobre el mercado de electricidad alemán APX, y se plantea la posibilidad de utilizar modelos de incertidumbre para diseñar estrategias en las ofertas de energía teniendo en cuenta la diferencia de los precios de los desvíos por exceso o por defecto de generación. Se obtienen mayores beneficios teniendo en cuenta la incertidumbre de las predicciones para la estrategia de oferta de potencia eólica, que ofertando al mercado una predicción puntual [33].

Atendiendo al caso concreto del sistema eléctrico español, se presenta en [40] un estudio que utiliza predicciones del modelo Sipreólico para un parque eólico que envía ofertas de venta de energía al mercado eléctrico. La reducción de ingresos debida a las posibles penalizaciones por desvíos en la energía comprometida en el mercado resulta inferior si se utiliza el modelo de predicción. En [34] se trata la estrategia de ofertas óptimas, utilizando además un modelo de predicción de precios.

Las penalizaciones en los desvíos, se aplican tanto si el parque eólico genera menos potencia de la acordada en el mercado como si tiene un exceso de producción sobre el valor comprometido, pues en ambos casos se debe hacer uso de las bandas de regulación. Para mitigar estos desvíos, se ha planteado la posibilidad de hacer ofertas conjuntas de generación hidráulica y eólica con el objetivo de minimizar las penalizaciones, encargándose la hidráulica de compensar los desvíos en la generación eólica prevista.

En [35] se presentan ofertas óptimas de generación, teniendo en cuenta la incertidumbre de la generación eólica para minimizar el riesgo de penalizaciones durante el día siguiente en el sistema eléctrico español. Además, se plantea el uso de un generador hidráulico para minimizar las penalizaciones por desvíos. En [36] y [37] se propone usar centrales de bombeo junto con un parque eólico para diseñar una estrategia óptima de operación y maximizar los beneficios en el mercado portugués.

El posible uso del recurso hidráulico para almacenar energía y compensar las variaciones de la potencia eólica ha dado lugar a estudios que plantean el tamaño óptimo que deberían tener estas centrales hidráulicas de bombeo para recuperar la energía eólica no integrable en la red [38], o para compensar las variaciones de eólica teniendo en cuenta la incertidumbre asociada [39], convirtiendo incluso el servicio de almacenamiento hidráulico en un mercado rentable.

3.6.1 Desvíos en la predicción.

El artículo 34 del RD 661/2007 establece el cálculo y liquidación del coste de los desvíos:

1. A las instalaciones que hayan elegido la opción a) del artículo 24.1, se les repercutirá el coste de desvío fijado en el mercado organizado por cada período de programación. El

coste del desvío, en cada hora, se repercutirá sobre la diferencia, en valor absoluto, entre la producción real y la previsión.

2. Estarán exentas del pago del coste de los desvíos aquellas instalaciones que habiendo elegido la opción a) del artículo 24.1 no tengan obligación de disponer de equipo de medida horaria, de acuerdo con el Reglamento de puntos de medida de los consumos y tránsitos de energía eléctrica, aprobado por el Real Decreto 2018/1997, de 26 de diciembre.

Coste de desvío

Las penalizaciones en los desvíos, se aplican tanto si el parque eólico genera menos potencia de la acordada en el mercado como si tiene un exceso de producción sobre el valor comprometido, pues en ambos casos se debe hacer uso de las bandas de regulación.

El programa previsto de producción de energía después de haber participado en el mercado diario y en el mercado intradiario, y en caso necesario después de las restricciones en tiempo real, no será casi nunca igual a la energía efectivamente producida originando un desvío por déficit o por exceso sobre la energía programada que el operador del sistema debe resolver utilizando energías de balance que reemplacen el déficit de energía creado por el desvío o para que sean reemplazadas por el exceso de energía renovable producido como desvío. El coste de las energías de balance repercute a los productores con desvío originando una pérdida de ingresos.

El coste del desvío unitario por MWh producido se obtiene por medio de la siguiente fórmula:

Ecuación 3.23
$$CDSVP_h = \frac{DSV_h \times (PME_h - PLDSV_h)}{MED_h} = \frac{CDSV_h}{MED_h}$$

Donde:

DSV_h : Desvío en la hora h calculado como diferencia entre la producción horaria medida y el programa horario final operativo que es el programa final del mercado menos la reducción por restricciones en tiempo real. Es positivo si la producción es mayor que el programa y negativo en caso contrario.

$PLDSV_h$: Precio liquidado del desvío a la instalación en la hora h . Es menor o igual que PMD_h cuando DSV_h es positivo y mayor o igual que PMD_h cuando DSV_h es negativo. Por tanto, $CDSVP_h$ siempre es positivo o cero.

Los costes de desvío se publican en REE, gracias al Sistema de Información del Operador del Sistema (SIOS).

SIOS ha sido desarrollado por Red Eléctrica para realizar las tareas de información y gestión de los procesos relacionados específicamente con el mercado eléctrico. El sistema ofrece completa información de acceso público en el servidor del SIOS en Internet.

Como responsable de la operación del sistema eléctrico, Red Eléctrica garantiza la continuidad y seguridad del suministro y la adecuada coordinación del conjunto generación-transporte. Para ello realiza una serie de procesos, a partir de la casación del mercado en el horizonte diario efectuada por el operador del mercado, hasta la definición de cada una de las programaciones horarias y la asignación de los servicios complementarios, que permiten la explotación segura y económica del sistema en tiempo real.

Los costes de desvío que afectan a los parques eólicos son los que están publicados como Coste Desvíos RD 66/2007, dentro de Desvíos Medidos.

Los Desvíos Medidos se definen como la diferencia entre la energía programada y la energía medida. El precio de los desvíos se calcula de acuerdo a lo establecido en el P.O.-14.

3.6.2 Exención del coste del desvío

Según el Artículo 34.2 del Real Decreto 611/2007, de 25 de mayo, "estarán exentas del pago del coste de los desvíos aquellas instalaciones que habiendo elegido la opción a) del artículo 24.1 no tengan obligación de disponer de equipo de medida horaria, de acuerdo con el Reglamento de puntos de medida de los consumos y tránsitos de energía eléctrica, aprobado por el Real Decreto 2018/1997, de 26 de diciembre."

Según el Reglamento de puntos de medida, RD 1110/2007, las instalaciones que no tienen obligación de disponer de equipo de medida horaria y que por tanto están exentas del coste del desvío son las que su potencia nominal es menor o igual a 15 kVA.

El precio del desvío de las unidades de programación donde se agrupan estas instalaciones será siempre el precio del mercado diario, con independencia de su sentido. De esta forma el coste del desvío será siempre cero. El coste del desvío de las instalaciones exentas lo asume la demanda nacional como menor cobro del excedente de la liquidación de los desvíos.

3.7 Referencias

- [1]: M.H. Bollen, *Understanding Power Quality Problems: Voltage Sags and Interruptions*, Wiley-IEEE Press.
- [2]: R.M. Gnativ y J.V. Milanović, "Qualitative and quantitative analysis of voltage sags in networks with significant penetration of embedded generation," *European Transactions on Electrical Power*.
- [3]: N. Jenkins, R. Allan, P. Crossley, D. Kirschen, y G. Strbac, *Embedded Generation*, The Institution of Engineering and Technology, 2000.
- [4]: G. Pepermans, J. Driesen, D. Haeseldonckx, R. Belmans, y W. D'haeseleer, "Distributed generation: definition, benefits and issues," *Energy Policy*
- [5]: *Global Wind Report*, Global Wind Energy Council - GWEC, 2012
- [6]: Universidad de Castilla la Mancha (UCLM), www.uclm.es
- [7]: J. Usaola, O. Ravelo, G. González, F. Soto, M.C. Dávila, y B. Díaz-Guerra, "Benefits for Wind Energy in Electricity Markets from Using Short Term Wind Power Prediction Tools.
- [8]: D. Bunn, *Comparative Models for Electrical Load Forecasting*, John Wiley & Sons, 1985.
- [9]: S. Thor y P. Weis-Taylor, "Long-term research and development needs for wind energy for the time frame 2000-2020," *Wind Energy*
- [10]: G. Giebel, L. Landberg, G. Kariniotakis, y R. Brownsword, "State-of-the-Art on Methods and Software Tools for Short-Term Prediction of Wind Energy Production," *Proc. of the 2003 European Wind Energy Association Conference, EWEC'03*
- [11]: P.A. Østergaard, "Ancillary services and the integration of substantial quantities of wind power," *Applied Energy*, vol. 83
- [12]: H. Abildgaard, D. Klaar, B. Kriszak, J. Rodriguez, y W. Winter, "European Wind Integration Study (EWIS) - Reference Study Towards a Successful Integration of Wind Power into European Electricity Grids,"
- [13]: S. Makridakis, S.C. Wheelwright, R.J. Hyndman, "Forecasting. methods and applications", John Wiley and Sons, Hoboken (NJ), 1998.
- [14]: S.A. DeLurgio, "Forecasting principles and applications", McGraw- Hill, Singapur, 1998.
- [15]: L.Landberg, G. Giebel, H.A. Nielsen, T.S. Nielsen, H. Madsen, "Short-term prediction - An overview", *Wind Energy*, Vol. 6, no. 3, 273-280, 2003.

- [16]: G. Giebel, L. Landberg, G. Kariniotakis, R. Brownsword, "State-of- the-art on methods and software tools for short-term prediction of wind energy production", Proceedings European Wind Energy Conference, Madrid, 8p, 2003.
- [17]: M.Marciukaitis, V.Katinas, A.Kavaliauskas, "Wind power usage and prediction prospects in Lithuania", Laboratory of Renewable Energy, Lithuanian Energy Institute, Lithuania, 2006.
- [18]: A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, E. Feitosa, "A review on the Young history of the wind power short-term prediction", Wind Energy, Division of Renewable Energies, Department of Energy, CIEMAT, Madrid, 2007.
- [19]: M. Lei, L. Shiyan, J. Chuanwen, "A review on the forecasting of wind speed and generated power", Department of Electrical Engineering, Shanghai Jiaotong University, China, 2008.
- [20]: J. Ramirez-Rosado, L. Fernandez-Jimenez, C. Monteiro, J.Sousa, R. Bessa, "Comparison of two new short-term wind-power forecasting systems", Department of Electrical Engineering University of Zaragoza, España, 2008.
- [21]: I.J. Ramírez-Rosado, L.A. Fernández-Jiménez, C. Monteiro, "Artificial neural network models for wind power short-term forecasting using weather predictions", Proceedings International Conference on Modelling, Identification and Control, Innsbruck, Austria, 128-132, 2006.
- [22]: T.S. Nielsen, A. Joensen, H. Madsen, L. Landberg, y G. Giebel, "A new reference for wind power forecasting," Wind Energy, vol. 1, 1998, págs. 29-34.
- [23]: L. Landberg y S.J. Watson, "Short-term prediction of local wind conditions," Boundary-Layer Meteorology, vol. 70, Jul. 1994, págs. 171-195.
- [24]: M. Gastón, L. Frías, I. Martí, "Exploring the limits of wind farm grouping for prediction error compensation", Proceedings European Wind Energy Conference, Atenas, 5p, 2006.
- [25]: <http://www.energiasrenovables.ciemat.es>
- [26]: <http://www.reoltec.net/recursos>
- [27]: S. Chan, D. Powell, M. Yoshimura, y D. Curtice, "Operations Requirements of Utilities With Wind Power Generation," IEEE Transactions on Power Apparatus and Systems, vol. PAS-102, 1983, págs. 2850-2860.
- [28]: M.R. Milligan, A.H. Miller, y F. Chapman, "Estimating the economic value of wind forecasting to utilities," 1995.
- [29]: S. Watson, G. Giebel, y A. Joensen, "The Economic Value of Accurate Wind Power Forecasting to Utilities," 1999.

- [30]: B. Sorensen y P. Meibom, "Can wind power be sold in a deregulated electricity market?," Proceedings of the European Wind Energy Conference, Nice, France: 1999, págs. 375-378.
- [31]: P. Pinson, C. Chevallier, y G. Kariniotakis, "Optimizing benefits from wind power participation in electricity markets using advanced tools for wind power forecasting and uncertainty assessment," Proceedings of the 2004 EWEC conference, London: 2004.
- [32]: P. Pinson, C. Chevallier, y G.N. Kariniotakis, "Trading Wind Generation From Short-Term Probabilistic Forecasts of Wind Power," IEEE Transactions on Power Systems, vol. 22, 2007, págs. 1148-1156.
- [33]: P. Pinson y G. Kariniotakis, "On-line adaptation of confidence intervals based on weather stability for wind power forecasting," Proceedings of the 2004 Global Wind Windpower Conference, Chicago, Illinois, USA: 2004.
- [34]: J. Usaola y M. Moreno, "Optimal bidding of wind energy in intraday markets," 2009 6th International Conference on the European Energy Market, Leuven: 2009, págs. 1-7.
- [35]: J.M. Angarita y J.G. Usaola, "Combining hydro-generation and wind energy: Biddings and operation on electricity spot markets," Electric Power Systems Research, vol. 77, Abr. 2007, págs. 393-400.
- [36]: E. Castronuovo y J. Lopes, "On the Optimization of the Daily Operation of a Wind-Hydro Power Plant," IEEE Transactions on Power Systems, vol. 19, 2004, págs. 1599-1606.
- [37]: E.D. Castronuovo y J.A.P. Lopes, "Optimal operation and hydro storage sizing of a wind-hydro power plant," International Journal of Electrical Power & Energy Systems, vol. 26, Dic. 2004, págs. 771-778.
- [38]: J. Anagnostopoulos y D. Papantonis, "Simulation and size optimization of a pumped-storage power plant for the recovery of wind-farms rejected energy," Renewable Energy, vol. 33, Jul. 2008, págs. 1685-1694.
- [39] P. Pinson, G. Papaefthymiou, B. Klockl, y J. Verboomen, "Dynamic sizing of energy storage for hedging wind power forecast uncertainty," Power Energy Society General Meeting, 2009. PES '09. IEEE, 2009, págs. 1 -8.
- [40]: J. Usaola, O. Ravelo, G. González, F. Soto, M.C. Dávila, y B. Díaz-Guerra, "Benefits for Wind Energy in Electricity Markets from Using Short Term Wind Power Prediction Tools; a Simulation Study," Wind Engineering, vol. 28, Ene. 2004, págs. 119-127

CAPÍTULO 4

Objetivo de La TESIS.

INDICE

4.1 Introducción.....	98
4.2 Objetivo General.....	99
4.3 Metodología.....	99
4.4 Referencias.....	100

4.1 Introducción

La contribución de las energías renovables a la demanda de energía eléctrica en Canarias era, a finales del año 2014, del 8,1%, según datos publicados por Red Eléctrica de España [1]. Este dato se encuentra muy alejado de la contribución del 40% asignada a España a través de la DIRECTIVA 2009/28/CE DEL PARLAMENTO EUROPEO [2].

El Gobierno de Canarias tiene entre sus estrategias energéticas aumentar la contribución de las energías renovables, y en particular de la energía eólica, a la demanda de la energía eléctrica. El Plan Energético de Canarias 2006-2015 (PECAN) es un documento estratégico que establece como objeto estratégico el que las energías renovables contribuyan en un 30% a la demanda de energía eléctrica [3]. Para el caso particular de la energía eólica se marca como objetivo 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 154 MW instalados a finales del 2014 [1], hará que el sector de la energía eólica, como fuente de energía renovable para la generación de energía eléctrica, tenga un marcado interés en los próximos años.

Las pequeñas y débiles redes eléctricas insulares representan una importante restricción técnica a la maximización de la penetración de energía eólica debido a la variabilidad de esta fuente primaria[4-6] que afecta a la estabilidad del sistema eléctrico insular. Esta afección se incrementará en un escenario de alta penetración de EERR.

En resumen, el crecimiento esperado en la contribución de las energías renovables en general y la eólica en particular, sobre la demanda de energía eléctrica y teniendo en cuenta la baja gestionabilidad del recurso eólico, hace preciso el disponer de modelos de predicción a muy corto plazo, inferior a 48 horas, de la potencia eléctrica de los parques eólicos, tanto para mejorar su integración técnica en los sistemas eléctricos insulares, como para su incorporación al mercado de la energía eléctrica.

En la literatura científica se pueden encontrar diferentes modelos para la predicción futura de la potencia eléctrica de parques eólicos [7-9]. Éstos presentan diversas fiabilidades o errores en la estimación que hace que los valores predichos, en muchos casos, disten en gran medida de los valores reales medidos.

4.2 Objetivo General

El objetivo general del trabajo de investigación que se propone es el de desarrollar un modelo de predicción de la potencia eléctrica de los parques eólicos utilizando técnicas de inteligencia artificial, concretamente las Redes Neuronales. Para ello se ha utilizado utilizará información relativa a parques eólicos ubicados en las islas Canarias.

4.3 Metodología seguida y objetivos específicos

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 información histórica de referencia relativa a datos meteorológicos (velocidades y direcciones media horarias) y de producción eléctrica de parques eólicos ubicados en las islas Canarias.
3. Desarrollo de un modelo dinámico de curva de potencia global del parque eólico utilizando las redes neuronales artificiales. Comparación de los resultados obtenidos a partir del modelo propuesto con los obtenidos a partir de la propia curva de potencia de los aerogeneradores (modelo estático)
4. Desarrollo del modelo de predicción futura de la potencia eléctrica del parque eólico utilizando las Redes Neuronales Artificiales. Para ello, se hará un análisis de la estructura de la red que optimice los resultados, es decir, que minimice el error cometido en la predicción con una buena correlación entre los datos estimados y reales. Este análisis se basará:
 - a) En el estudio de la influencia de los datos en la capa de entrada a la red: velocidades y direcciones del viento de los instantes anteriores al de predicción, datos de producción del parque eólico en dichos instantes anteriores, velocidades y direcciones para los instantes de predicción
 - b) En el estudio de la influencia de la incorporación a la capa de entrada de la red neuronal de la información meteorológica de otras estaciones, diferentes a la de referencia del parque eólico.
5. Presentación de Conclusiones y Líneas futuras de actuación

4.4 Referencias

- [1] Red Eléctrica de España. El sistema eléctrico español. 2014. <http://www.ree.es/es/publicaciones/sistema-electrico-espanol/informe-anual/informe-del-sistema-electrico-espanol-2014>.
- [2] Parlamento Europeo y del Consejo. Directiva 2009/28/CE de 23 de abril de 2009 relativa al fomento del uso de energía procedente de fuentes renovables. Diario oficial de la Unión Europea. 2009: pp L140/16 L149/62
- [3] Gobierno de Canarias. Plan Energético de Canarias. <http://www.gobiernodecanarias.org/energia/doc/planificacion/pecan/pecan2007.pdf>. (último acceso 30/10/2013).
- [4] Justus CG, Mani K, Mikhail AS. Interannual and month-to-month variations of wind speed. *Journal of Applied Meteorology* 1979; 18:913–20.
- [5] 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.
- [6] Klink K. Trends and interannual variability of wind speed distributions in Minnesota. *J. Clim.* 2002; 15: 3311-7.
- [7] Costa A., Crespo A., Navarro J., Lizcano G., Madsen H., Feitosa E. A review on the young history of the wind power short-term prediction. *Renewable and Sustainable Energy Reviews* 2008; 12: 1725–44
- [8] Grazia De Giorgi M. , Ficarella A., Tarantino M. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. *Energy* 2011; 36: 3968-78
- [9] Lei M., Shiyang L., Chuanwen J., Hongling L., Yan Z. A review on the forecasting of wind speed and generated power. *Renewable and Sustainable Energy Reviews* 2009; 13: 915–20

CAPÍTULO 5

Estado del arte en la predicción de la potencia eléctrica de origen eólico

INDICE

5.1. Introducción.....	104
5.2. Predicción numérica del tiempo.....	104
5.2.1 Modelos atmosféricos de macro-escala globales.....	106
5.2.2 Modelos atmosféricos de macro-escala Regionales.....	107
5.2.3 Modelos atmosféricos meso-escalares y de micro-escala.....	108
5.2.4 Conclusiones.....	113
5.3 Técnicas utilizadas en los modelos de predicción eólica.....	114
5.3.1 Modelos físicos.....	115
5.3.2 Modelos estadísticos.....	117
5.3.2.1 MOS.....	118
5.3.2.2 Filtros de Kalman.....	119
5.3.2.3 Modelos ARIMA.....	120
5.3.2.4 Redes Neuronales Artificiales.....	120
5.3.2.5 Fuzzy Logic: Sistemas de Inferencia Difusa.....	123
5.3.2.6 Conclusiones.....	125
5.3.3 Comparación de modelos.....	126
5.4 La herramienta de predicción SIPREÓLICO.....	128
5.4.1 Datos de entrada.....	129
5.4.2 Modelos de predicción de Sipreólico.....	131
5.5 El proyecto ANEMOS.....	134
5.6 Descripción y características de los modelos de predicción existentes.....	136
5.6.1 Aeolis.....	138
5.6.2 Casandra.....	140
5.6.3 CENER.....	143
5.6.4 Meteológica.....	145
5.7 Otros modelos.....	147
5.7.1 Aleasoft.....	147
5.7.2 Garrad Hassan.....	149
5.7.3 Meteosim.....	153
5.7.4 EA2.....	154
5.8 Ejercicio de Predicción.....	156
5.9 Referencias.....	158

ÍNDICE DE FIGURAS:

Figura 5.1: Modelo Global de Alemania con una resolución espacial de 60 x 60 km²

Figura 5.2: Dominio del modelo Local del Servicio Meteorológico Alemán con una resolución espacial de 7 x 7 km²

Figura 5.3: Anidamiento de dominios para la ejecución del modelo atmosférico MM5 con una elevada resolución espacial para una zona de La Rioja

Figura 5.4: Curva de potencia del aerogenerador G90-2.0 MW fabricado por Gamesa Corporación Tecnológica

Figura 5.5: Mejora en la predicción utilizando filtros de Kalman

Figura 5.6: Esquema básico de red neuronal utilizado en WPMS

Figura 5.7: Estructura de un sistema de inferencia difusa

Figura 5.8: Mejora del error de predicción (RMSE) de la velocidad de viento en el parque de Alaiz

Figura 5.9: Errores (RMSE) de las predicciones de viento para Alaiz de los modelos: MM5, MM5+CFD, MM5+LocalPred, MM5+CFD+MOS

Figura 5.10: Diagrama de funcionamiento de SIPREEÓLICO

Figura 5.11: Esquema del módulo de predicción de Sipleólico

Figura 5.12: Esquema de los modelos de predicción

Figura 5.13: Predicción de producción eólica nacional

Figura 5.14: Características del modelo Aeolis

Figura 5.15: Esquema de funcionamiento del modelo Casandra

Figura 5.16: Características del modelo CENER

Figura 5.17: Predicción regional de generación eólica en Alemania y observaciones en tiempo real

Figura 5.18: Características del modelo Meteorológica

Figura 5.19: Esquema general de funcionamiento AleaSoft

Figura 5.20: Características del modelo AleaSoft

Figura 5.21: Ejemplo de serie temporal de una predicción de velocidad de viento, T+12h

Figura 5.22: Ejemplo de serie temporal de una predicción de energía, T + 12 h

Figura 5.23: Características del modelo Garrad Hassan

Figura 5.24: Características del modelo eWind

Figura 5.25: Arquitectura del sistema EA2

ÍNDICE DE TABLAS:

Tabla 5.1: Sistemas de predicción numérica del tiempo en Europa

5.1 Introducción

Se pueden encontrar dos clases de modelos de predicción de potencia eólica atendiendo a si usan o no predicciones meteorológicas (Numerical Weather Predictions o NWP). Normalmente, para calcular predicciones de generación eólica es necesario disponer previamente de predicciones meteorológicas, salvo para los modelos de predicción de potencia basados exclusivamente en extrapolar la tendencia de la producción eólica.

5.2 Predicción Numérica del Tiempo. (NWP)

Generalmente, para calcular predicciones de generación eólica es necesario disponer previamente de predicciones meteorológicas, salvo para los modelos de predicción de potencia basados exclusivamente en extrapolar la tendencia de la producción eólica.

Los modelos de predicción numérica operativos en los centros de predicción meteorológica aportan el dato de entrada principal para poder predecir la energía eólica a corto plazo. Actualmente, cualquier ejercicio de predicción se apoya en este tipo de predicciones meteorológicas aunque se sabe que estos modelos presentan errores considerables y sistemáticos en las capas próximas en el suelo.

Son varias las opciones para mejorar esta limitación, entre las que se encuentra la aplicación de modelos estadísticos o empíricos, proceso que se suele denominar "Downscaling estadístico" o modelización estadística de las predicciones a nivel local. Otra opción ampliamente utilizada es el uso de modelos numéricos de mayor resolución que se anidan a los modelos meteorológicos, y que se denominan "Downscaling físico" o modelización física de adaptación de las predicciones a nivel local.

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

La atmósfera es, esencialmente, una mezcla de gases y agua en sus distintos estados. Esta mezcla se encuentra en un continuo movimiento, sometida a la acción del campo gravitatorio de la propia Tierra. Además sobre esta mezcla está actuando la radiación solar, responsable del calentamiento de la misma. Pero como en cualquier sistema real, se cumplen un conjunto de leyes físicas: leyes de conservación de energía, masa y momento, además de la ecuación de estado de los gases. Estas leyes físicas se pueden representar mediante ecuaciones diferenciales que relacionan las derivadas totales de ciertas magnitudes físicas respecto a la variable tiempo.

Las ecuaciones diferenciales que corresponden a la modelización matemática de las leyes físicas que rigen el comportamiento dinámico de la atmósfera, reciben la denominación de ecuaciones primitiva. La resolución de dichas ecuaciones proporcionará unos resultados numéricos para las variables que intervienen en las mismas. Esta es la base de la predicción numérica meteorológica.

El objetivo de la predicción numérica meteorológica es determinar el estado de la atmósfera para un instante futuro, a partir de la condición inicial actual. Para ese objetivo se debe disponer de un modelo matemático capaz de resolver las ecuaciones primitivas y que incluya los posibles intercambios energéticos (radiación, turbulencia, calor latente, etc.). Puesto que las ecuaciones primitivas son no lineales, en la práctica se suele recurrir a distintas aproximaciones que simplifican la resolución numérica.

Para la obtención de las soluciones numéricas, aparecen los modelos atmosféricos que asignan al mundo real continuo una rejilla tridimensional. La resolución espacial de esa rejilla, influye directamente en la precisión del modelo atmosférico. Así una disminución del tamaño de la rejilla significará un aumento de la precisión, si bien, también significará un aumento en el tiempo computacional necesario para la resolución de las ecuaciones: a la par que reducimos el tamaño de la rejilla, debe reducirse el paso de integración utilizado en las técnicas numéricas de resolución, para poder mantener la estabilidad de las soluciones. Una importante área de investigación en el campo de la predicción meteorológica, hoy en día, lo constituye el aumento de la resolución en los modelos, sin que este aumento de resolución signifique importantes incrementos en el tiempo computacional para la resolución de los mismos.

Establecer el estado inicial para ejecutar una predicción requiere una gran colección de datos. El estado de la atmósfera se mide sobre una base regular por un gran número de estaciones sinópticas, boyas, radio sondas, barcos, satélites y aviones en todo el mundo. Como los formatos de los datos y los ciclos de medición se encuentran estandarizados por la Organización Mundial Meteorológica (OMM), se encuentran disponibles los datos mundiales meteorológicos para los servicios meteorológicos y así poder establecer las condiciones iniciales de sus modelos de predicción numérica del tiempo.

Por tanto, los modelos de predicción meteorológica se basan en la resolución de las ecuaciones físicas que describen el estado de la atmósfera, aplicadas a una serie de puntos de una malla o rejilla tridimensional que la representa y que, partiendo de unos valores iniciales de medidas del estado de la atmósfera, calculan cómo será la evolución de la misma durante las siguientes horas. Típicamente, un modelo de predicción meteorológica se ejecuta cada 6 o 12 horas, generando predicciones para las siguientes 48 o 72 horas.

Dependiendo de la escala espacial o tamaño de rejilla que utilicen los modelos, podemos diferenciar entre modelos de macro-escala, modelos meso-escalares, y modelos de micro-escala.

5.2.1 Modelos atmosféricos de macro-escala globales.

Los modelos atmosféricos de macro-escala globales utilizan una aproximación hidrostática, es decir, los movimientos verticales de las masas de aire se suponen despreciables frente a los movimientos horizontales, y por lo tanto no tienen en cuenta la posible evolución vertical de la atmósfera. Al abarcar toda la superficie terrestre tienen su malla definida en coordenadas esféricas. Ejemplos de modelos de macro-escala globales son el GFS (Global Forecast System) del servicio meteorológico norteamericano NCEP (National Centers for Environmental Prediction) [1], el perteneciente al centro europeo de predicción ECMWF (European Centre for Medium-Range Weather Forecasts), y el modelo global de Alemania actualmente con resoluciones espaciales entre 0.5° y 0.25° .

En la figura 3.1 se puede observar un ejemplo de la malla del modelo global del Servicio Meteorológico Alemán. Al ser un modelo global, presenta una resolución de 60 x 60 km².

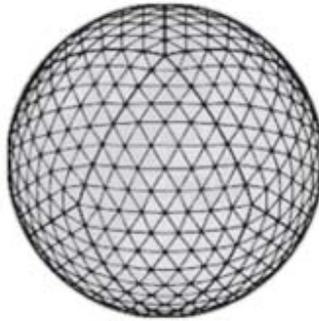


Figura 5.1: Modelo Global de Alemania con una resolución espacial de 60 x 60 km².

Fuente: Physical Approach to Short-Term Wind Power Prediction

5.2.2 Modelos atmosféricos de macro-escala regionales.

Dado que las regiones de mayor interés en la predicción meteorológica no abarcan todo el planeta, también existen otros modelos de macro-escala no globales que centran su predicción en las regiones de interés. Estos modelos están limitados a una región específica, con lo que con la misma potencia de cálculo pueden tener una resolución mayor que los modelos globales. Para su ejecución, además de condiciones iniciales necesitan condiciones de contorno de la región, que son obtenidas de los modelos globales. El modelo HIRLAM (High Resolution Limited Area Model) es un ejemplo de modelo atmosférico regional, que actualmente ofrece predicciones para parte de Europa con resolución espacial entre 0.05° y 0.16°.

A partir del modelo global, aparece el modelo local o regional con una mayor resolución de entre 50 x 50 km² hasta 7 x 7 km² pero con un dominio menor que normalmente se centra alrededor del país de origen del servicio meteorológico. En la figura 3.2 se puede observar un ejemplo.

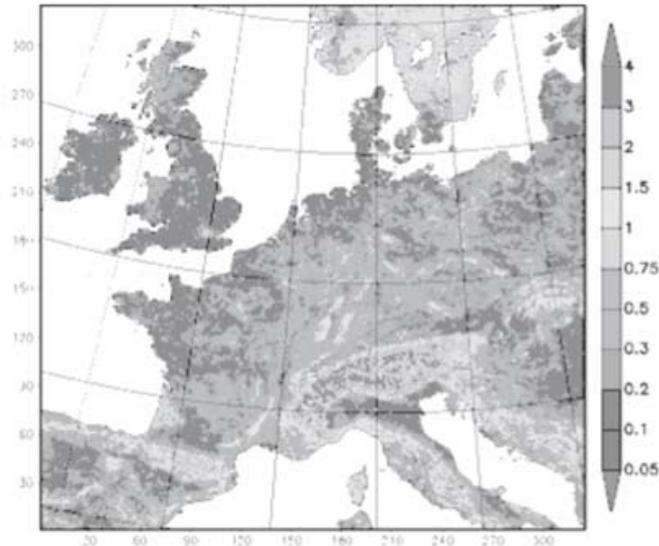


Figura 5.2: Dominio del modelo Local del Servicio Meteorológico Alemán con una resolución espacial de 7 x 7 km².

Fuente: Physical Approach to Short-Term Wind Power Prediction

5.2.3 Modelos atmosféricos meso-escalares y de micro-escala.

Debido a la limitación computacional de los ordenadores, la separación entre dos puntos consecutivos de la malla que usan los modelos atmosféricos macro-escalares como los descritos es superior al tamaño característico de un parque eólico. Dado que los puntos de la malla para los que se calcula la predicción de viento no suelen coincidir con la ubicación de los parques eólicos, la predicción de viento en el emplazamiento de un parque se obtiene mediante una interpolación entre los valores de los puntos de la rejilla más cercanos resueltos en el modelo atmosférico. Además, esta malla tampoco suele tener la resolución suficiente como para representar con un detalle adecuado la orografía del terreno, con lo que las predicciones de viento a baja altura y en terrenos complejos suelen ser bastante deficientes.

Para tratar de paliar estos inconvenientes, existen modelos de menor escala que, partiendo de las predicciones meteorológicas de un modelo de macro-escala en los puntos de la malla cercanos a la ubicación del parque eólico, vuelven a resolver las ecuaciones físicas sin usar una aproximación hidrostática, teniendo en cuenta la aceleración vertical provocada por la orografía del terreno. Esta vez se define una

malla mucho más fina, localizada en el entorno del emplazamiento del parque eólico y representando con gran detalle la orografía del terreno en coordenadas cartesianas. Ejemplos de modelos meso-escalares son MM5 y RAMS [2,3], y WAsP es un caso representativo de modelo de micro-escala [4].

En particular, la ventaja de los modelos de mesoescala consiste en un detalle mayor de los efectos térmicos, que es muy beneficioso en terrenos con alta radiación solar y cerca de la costa para capturar las brisas marinas. Estos modelos también son importantes para terrenos complejos, por ejemplo, en España o Noruega, donde la velocidad y dirección del viento es localmente no homogénea.

Son varios los modelos atmosféricos no hidrostáticos (mesoescala) desarrollados por la comunidad científica, alguno de ellos implementados en software de acceso público. Entre estos pueden citarse el modelo atmosférico WRF (Weather Research and Forecast Model), el MM5 (Penn State/NCAR Mesoscale Model, Version 5), COAMPS (US Navy's Coupled Ocean/Atmosphere Mesoscale Prediction System), ARPS (Advanced Regional Prediction System), MEMO (Mesoscale Model) etc. La mayoría de los modelos atmosféricos están programados en Fortran, con algunas rutinas en C, y pensados para ser ejecutados en ordenadores con sistema operativo Unix.

Cabe destacar el modelo atmosférico MM5. Es un modelo atmosférico de mesoescala, desarrollado por investigadores de la Universidad Estatal de Pennsylvania y el National Center for Atmospheric Research (PSU/NCAR), desde la década de los 80 del siglo pasado. Está implementado en más de 100.000 líneas de código programado en Fortran 77, Fortran 90 y C. El modelo está soportado por un conjunto de programas, que pueden ser compilados para funcionar de forma paralela en varias máquinas (un "cluster" de máquinas). Este modelo es la última versión de una serie de modelos evolucionados a partir de un modelo de mesoescala desarrollado durante los años ochenta. Desde entonces ha sufrido numerosas modificaciones, convirtiéndose en uno de los modelos de mesoescala de referencia a nivel mundial. Entre sus características más relevantes se pueden destacar la capacidad de anidamiento múltiple, su dinámica de fluidos no hidrostática, y la capacidad de asimilación de datos en cuatro dimensiones. También incluye un gran número de procesos físicos opcionales y su portabilidad a un gran número de plataformas computacionales.

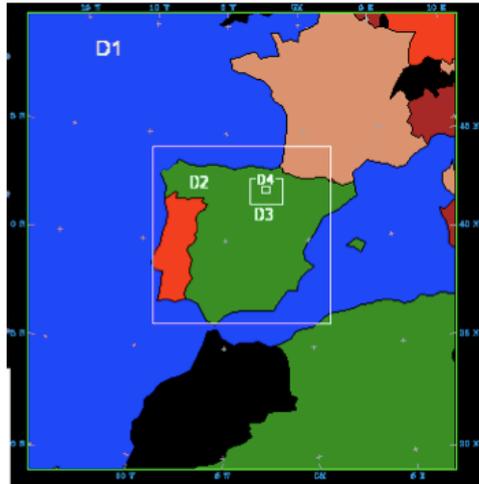


Figura 5.3: Anidamiento de dominios para la ejecución del modelo atmosférico MM5 con una elevada resolución espacial para una zona de La Rioja.

Fuente: MM5

Con estas técnicas se pueden mejorar y adaptar a una zona localizada las predicciones meteorológicas de un modelo atmosférico global o regional. Así, por medio de una representación más detallada de la topografía se pueden mejorar los resultados de los modelos de predicción de viento en una zona concreta [5].

La tabla 5.1 muestra una visión general de los sistemas de predicción numérica del tiempo, operados por los servicios meteorológicos europeos:

Tabla 5.1: Sistemas de predicción numérica del tiempo en Europa.

Fuente: Physical Approach to Short-Term Wind Power Prediction

Nombre del modelo	Servicio Meteorológico	Resolución horizontal (km)
Modelo global	Servicio Meteorológico Alemán	60
Modelo local	Alemán	7
Arpege	Meteo France	19-250
Aladin		9,5
Hirlam	Suecia, Dinamarca, Noruega, España, Islandia, Irlanda, Finlandia, los Países Bajos	10-50
ECMWF	Centro Europeo de Previsiones Meteorológicas a Medio Plazo	40
Unified Model	MetOffice, UK	60/11

Estos modelos, atendidos por los institutos meteorológicos, debido a los altos requerimientos computacionales que se han comentado y a la inmediatez relativa de obtención de resultados, no han sido diseñados para realizar unas predicciones precisas del viento en la superficie del terreno, y menos aún para el rango de velocidades entre 5 y 15 m/s (no son vientos ni muy flojos ni muy fuertes). Para la predicción de la potencia eléctrica generada en un parque eólico la variable meteorológica mas importante es el viento. Y es, justamente, en el rango de velocidades del viento antes citado, donde actualmente aparece la mayor variabilidad en la potencia eléctrica generada en un aerogenerador.

La figura 5.4 presenta la curva de potencia (potencia generada en función de la velocidad del viento, con condiciones constante) para un aerogenerador de última generación. Como se puede apreciar la mayor variación de potencia eléctrica generada se da en el rango de velocidades de viento de 4 a 12 m/s, aproximadamente. Por ejemplo, para una velocidad del viento de 10 m/s, la potencia generada es del orden de 8 veces más que para una velocidad del viento de la mitad de ese valor, es decir, 5 m/s. Un ligero error en la predicción de la velocidad del viento por parte del modelo atmosférico puede significar un alto error de predicción en la potencia eléctrica generada.

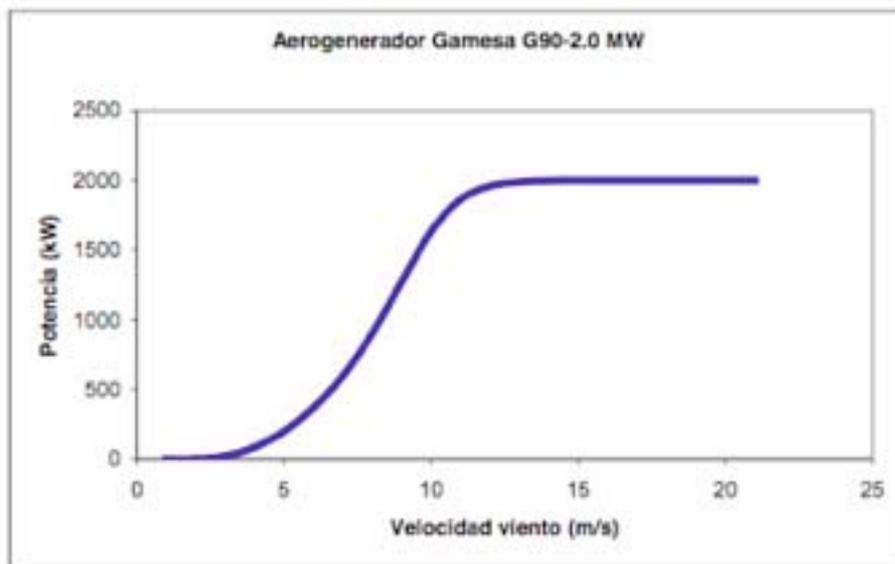


Figura 5.4: Curva de potencia del aerogenerador G90-2.0 MW fabricado por Gamesa Corporación Tecnológica.

Fuente: Gamesa

Por último, se debe tener en cuenta que las condiciones iniciales de cálculo del modelo numérico de predicción meteorológica determinan la evolución de la predicción de viento. Esto se convierte en una posible fuente de error, pues unas condiciones iniciales incorrectas, consecuencia de errores en el proceso de medida o interpretación de las variables de estado de partida, darán lugar a una evolución distinta a la real, con diferencias entre los valores de las variables meteorológicas previstas y las reales.

Todas estas aproximaciones introducen fuentes de error en la predicción del viento en el emplazamiento del parque, que posteriormente se traducirán de forma

amplificada en una incertidumbre en la predicción de potencia debido al crecimiento cúbico de la potencia con el viento en la zona de trabajo de los aerogeneradores, ecuación 1.2. Por ello, en general se considera que la mayor fuente de error en las predicciones de potencia eólica se debe al paso previo, el de la predicción meteorológica [6]

Con el paso de los años, han ido aumentando los recursos informáticos y estos modelos han crecido, mejorando así la predicción de la producción eléctrica en parques eólicos.

5.2.4 Conclusiones.

Tanto los modelos atmosféricos de macro escala (gran escala) como los de micro escala estudian fenómenos cuyas escalas escapan de las variables de interés en la predicción de la producción eléctrica en parques eólicos. Para esta tarea, los modelos atmosféricos que pueden aportar la información con mayor interés (viento en superficie) son los modelos de mesoescala, al menos en su escala espacial. Como se ha comentado anteriormente, la escala temporal de un modelo de mesoescala puede aumentarse si sus condiciones iniciales se establecen a partir de un modelo de mayor escala.

El desarrollo tecnológico de computadores cada vez más potentes ha permitido la implementación, en forma de programas, de los modelos numéricos de predicción atmosférica. Estos programas permiten la asimilación masiva de datos meteorológicos para poder determinar las condiciones iniciales de la atmosfera, tarea esencial para poder predecir el futuro estado meteorológico de la misma.

Existen distintos modelos atmosféricos operativos, que se diferencian fundamentalmente en la resolución espacial y temporal. Cuanto mayor es la resolución espacial de un modelo atmosférico, menor es su alcance temporal (plazo de validez de las predicciones). Los modelos atmosféricos clasificados como gran escala, son los que tienen una resolución espacial menor.

Para la predicción de la velocidad del viento en una localización geográfica concreta (situación de un parque eólico), los modelos atmosféricos que ofrecen una mayor resolución son los modelos atmosféricos mesoescalares, alguno de ellos implementado en software de libre distribución. El modelo atmosférico MM5 es uno de estos modelos con mayor aceptación en la comunidad científica. Proporciona, como resultado de la simulación, el valor de determinadas variables meteorológicas para todos los puntos de la rejilla tridimensional de análisis, y para todos los intervalos temporales definidos por el usuario. Dentro de las múltiples parametrizaciones que admite, para poder particularizar la simulación dinámica de la evolución de la atmósfera para cualquier caso, ofrece la de generar series temporales de variables meteorológicas, entre ellas el viento.

5.3 Técnicas utilizadas en los modelos de predicción eólica

Existen dos aproximaciones básicas para la predicción de la energía eólica a corto plazo, los modelos físicos y los modelos estadísticos.

Los modelos físicos tienen en cuenta consideraciones físicas para adaptar las predicciones de viento en una zona a las condiciones concretas del emplazamiento del parque. Para hacer esta adaptación se utilizan modelos de meso-escala o micro-escala que, partiendo de las condiciones iniciales y de contorno obtenidas de un modelo atmosférico de mayor escala, calculan la velocidad del viento incidente en las turbinas del parque para posteriormente calcular la predicción de potencia por medio de la curva de potencia.

Por otro lado, de entre los modelos estadísticos podemos encontrar la familia de las series temporales, que solo utilizan valores pasados de las variables como datos de entrada del modelo, y los que además de valores pasados utilizan como entradas los valores de predicción meteorológica de modelos atmosféricos, relacionándolos con los valores de potencia histórica u otros valores históricos medidos.

El modelo de predicción podría ser una combinación de ambos, es decir, tener en cuenta consideraciones físicas para estimar con detalle el viento en el emplazamiento

de las turbinas y usar modelos estadísticos avanzados que utilicen esta información localizada, además de las medidas de potencia, para minimizar el error.

A continuación, se resumen los principales aspectos de los sistemas más representativos utilizados en la actualidad para calcular predicciones de generación eólica, algunos de ellos basados en modelos físicos, otros en modelos estadísticos, y combinaciones de ambos.

5.3.1 Modelos físicos.

Los modelos físicos se basan en el modelado físico del emplazamiento donde se encuentran los aerogeneradores, y tratan de predecir el viento que incidirá en cada una de las turbinas para, mediante el conocimiento de las características de las turbinas y su curva de potencia, poder dar una predicción de potencia eólica.

En primer lugar, dado el viento previsto por algún modelo global o regional en las proximidades del parque eólico, se debe hacer una adaptación de la predicción de viento al emplazamiento concreto del parque usando un modelo de meso-escala o micro-escala, para estimar el viento en la posición y altura donde se encuentran las turbinas eólicas. Posteriormente, se transforma esta velocidad del viento en un valor de potencia mediante el uso de la curva de potencia propia de las máquinas instaladas.

Una de las ventajas de los modelos físicos es que para su implementación no se necesitan datos históricos, a menos que se le añada un módulo estadístico para corregir los posibles sesgos o defectos de escala. De hecho, la mayoría de los modelos físicos incorporan un módulo estadístico MOS, o Model Output Statistics, para considerar los posibles efectos que no tienen en cuenta los modelos físicos y realizar las correcciones oportunas [7]. Así pues, en la práctica casi todos los modelos físicos se podrían considerar híbridos, pues suelen incorporar un módulo estadístico de mayor o menor complejidad.

El modelo Prediktor, desarrollado por Landberg en el Risø National Laboratory de Dinamarca para la operadora del sistema eléctrico Elkraft es un ejemplo de modelo físico [8]. Utiliza WAsP (Wind Atlas Analysis and Application Program) para convertir las

predicciones meteorológicas del modelo atmosférico HIRLAM en viento sobre las turbinas de un parque, y calcula la predicción de potencia mediante el uso de la curva de potencia. El efecto de estela de las turbinas se tiene en cuenta mediante el uso de PARK, que modela este efecto basándose en la información de la posición relativa de las turbinas dentro del parque. Los demás efectos que no tienen en cuenta los modelos físicos se corrigen con un modelo estadístico o MOS, ajustando los resultados con las medidas de potencia históricas.

En la actualidad, el modelo Prediktor forma parte, junto con el modelo estadístico Wind Power Prediction Tool (WPPT), de la herramienta Zephyr [9], que tiene el objetivo de aunar las ventajas de un modelo estadístico y un modelo físico. El modelo estadístico proporciona buenos resultados para las primeras horas mientras que el modelo físico proporciona mejores resultados para horizontes mayores, incluso ante la ausencia de medidas de potencia.

Previento [10], desarrollado por Focken en la universidad de Oldenburg, es otro ejemplo representativo de modelo físico, que en este caso utiliza predicciones meteorológicas LokalModell del servicio meteorológico alemán DWD [11]. Posteriormente calcula predicciones regionales totales a partir de las predicciones individuales de algunos parques seleccionados.

En Estados Unidos, la herramienta EWind [12], desarrollada por TrueWind, usa el modelo de meso-escala ForeWind para adaptar las predicciones a condiciones locales, tomando como condiciones iniciales y de contorno las predicciones meteorológicas de un modelo de mayor ámbito [13]. Los errores sistemáticos también se atenúan con el uso de un módulo estadístico.

CENER y CIEMAT han desarrollado Localpred [14], [15], pensado para hacer predicciones en terrenos complejos y que está basado en un modelo de predicción de velocidad de viento local por la interpolación y corrección de puntos cercanos HIRLAM con regresión múltiple. Incluye predicciones a muy corto plazo basadas en modelos de series temporales, e incorpora un modelado físico del terreno en alta resolución con el modelo de meso-escala MM5 para mejorar las predicciones meteorológicas en el entorno del parque eólico y transformarlas en predicciones de potencia mediante una curva de potencia.

Por último, también se han propuesto herramientas de predicción de potencia que están basadas directamente en los modelos de previsión atmosféricos. Un ejemplo de esta integración directa del modelo de predicción meteorológica a un modelo de predicción de potencia eólica es el HIRLAM Power Prediction Model, o HIRPOM [16].

5.3.2 Modelos estadísticos.

Los modelos estadísticos también conocidos como “downscaling estadístico”, no simulan los procesos físicos explícitamente, como ocurre con los modelos físicos, sino que parametrizan las relaciones existentes entre los pronósticos meteorológicos y las producciones del parque. La principal ventaja de este tipo de modelos es que requieren un menor coste computacional al no tener que simular matemáticamente los complejos fenómenos físicos que influyen en la predicción de la producción de energía eólica y sus interrelaciones. Sin embargo, los modelos estadísticos requieren de un amplio histórico de datos para su entrenamiento y son más susceptibles a cambios en las condiciones de un parque.

Se considera un método de predicción estadístico, aquel que intenta establecer la relación entre los valores históricos de potencia eólica, y una serie de variables que pudieron tener relación con ese valor, como las predicciones NWP de las áreas cercanas, o variables climáticas (presión, humedad, temperatura...). Esta relación es encontrada mediante el uso de un conjunto de datos de entrenamiento.

El uso de modelos de predicción estadística que sólo utilizan valores pasados de potencia, pueden obtener un buen resultado para horizontes de predicción muy bajos (del orden de varias horas). Sin embargo es necesario el uso de predicciones climáticas NWP como variables de entrada para obtener un buen resultado en la estimación de la potencia eólica con un horizonte de predicción mayor.

Para simplificar, bajo la denominación de los modelos estadísticos considerados en el proyecto, también se han incluido a aquellos que utilizan técnicas que no pertenecen exactamente al campo de la estadística como son aquellos basados en redes neuronales y lógica borrosa.

En lo que respecta a las herramientas de predicción de tipo estadístico, la mayoría de éstas se basan en modelos "MOS" ("Model Output Statistics"), nombre con el que se empezaron a denominar a los primeros modelos clásicos de regresión lineal utilizados para aumentar la resolución de los resultados de los modelos numéricos. Por otra parte, también se han analizado modelos basados en filtros de Kalman.

5.3.2.1 MOS

El acrónimo MOS significa técnica de interpretación estadística de la salida de los modelos numéricos (Model Output Statistics).

Los sistemas de predicción numéricos se ven limitados rápidamente por la capacidad de cálculo de los ordenadores en la resolución de los fenómenos locales. Sin embargo, la utilización del procedimiento estadístico MOS permite, por ejemplo, predecir con mayor precisión la temperatura en pequeñas depresiones del terreno, los vientos locales, las precipitaciones en las cuencas hidrográficas o las horas de sol en las zonas con pendientes.

La técnica MOS resulta muy sencilla de aplicar, pero tiene el inconveniente de precisar una gran cantidad de datos obtenidos del modelo atmosférico (e incluso de medidas reales) para poder aplicar la regresión lineal múltiple y poder reducir los errores en la predicción de las variables (velocidad y dirección media del viento) que resulten de mayor interés para la predicción a corto plazo de la potencia eléctrica generada en parques eólicos.

MOS permite una corrección estadística, para adecuar la predicción a la ubicación concreta de cada parque. Según [17], para mejorar las predicciones de los modelos basados en técnicas MOS se muestran tremendamente útiles además de los valores de viento, los gradientes de presión.

5.3.2.2 Filtros de Kalman

Una técnica diferente a la MOS que contribuye a la reducción de los errores de predicción de los modelos atmosféricos (requiriendo una menor cantidad de datos), es la de aplicación de un filtro Kalman [18].

El filtro de Kalman es un algoritmo desarrollado por Rudolf E. Kalman en 1960 que sirve para poder identificar el estado oculto (no medible) de un sistema dinámico lineal.

Las técnicas de downscaling basadas en filtros de Kalman, muy apropiadas para estimar los estados de un sistema dinámico lineal, han conseguido reducciones del error en el pronóstico de hasta un 20% en algunos casos, especialmente en horizontes de predicción largos [17].

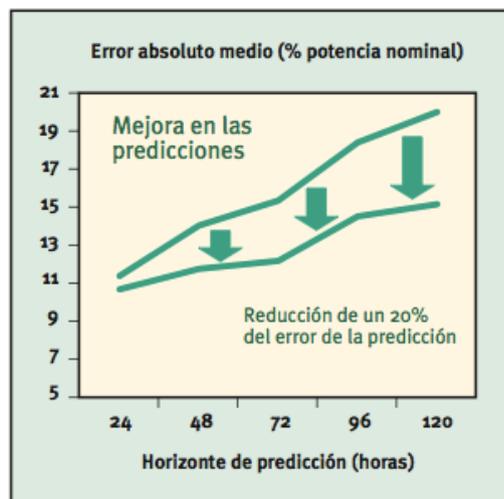


Figura 5.5: Mejora en la predicción utilizando filtros de Kalman.

Fuente: ANEMOS

El inconveniente que presentan los filtros Kalman, en el contexto de los datos disponibles para el desarrollo de los modelos de predicción a corto plazo de la potencia eléctrica generada en el parque eólico, es que precisan de valores medidos (reales) de las variables que son filtradas para actualizar los parámetros del filtro. Se ha

comentado en las anteriores páginas que las medidas de las variables meteorológicas disponibles en el parque no eran fiables. En este sentido conviene desarrollar un modelo de predicción que sea lo más independiente posible de medidas en el propio parque eólico.

5.3.2.3 Modelos ARIMA

El acrónimo ARIMA significa modelo autorregresivo integrado de media móvil (AutoRegresive Integrated Moving Average).

Los modelos ARIMA fueron popularizados en los años 70 por George Box y Gwilym Jenkins, y sus nombres se utilizan, frecuentemente, como sinónimos de la metodología ARIMA aplicada a análisis y predicción de series. Esta familia de modelos ha sido utilizada ampliamente a partir de los 80, debido a los avances de recursos de cálculo y de optimización.

La principal ventaja de esta metodología es que proporciona predicciones óptimas en el plazo inmediato y en el corto plazo.

Los modelos ARIMA presentan como una limitación el hecho de que sean modelos lineales, lo que los hace relativamente imprecisos en la predicción de variables de naturaleza no lineal. En la literatura especializada se puede encontrar una gran colección de modelos, derivados de los creados bajo la metodología de los modelos ARIMA, pero de carácter no lineal.

5.3.2.4 Redes neuronales artificiales (ANN)

Las redes neuronales artificiales son sistemas inspirados en los sistemas neuronales biológicos (cerebro animal). Las redes neuronales artificiales constan de un conjunto de elementos simples de procesamiento, llamados neuronas o nodos, conectados entre sí por conexiones que tienen asignado valor numérico modificable llamado peso. Cada neurona puede recibir información de otras neuronas (que actúan para ella como entradas) o de una entrada externa, y a su vez generar información en una salida que puede servir de información de entrada a otras neuronas. El procesamiento que cada

neurona hace con la información que recibe consiste en generar un valor (información) de salida que es función de una combinación lineal de valores de sus entradas.

La estructura de una red neuronal viene determinada por la disposición de las neuronas y de sus funciones de activación. Las neuronas se agrupan en capas, considerándose como "ocultas" aquellas que no corresponden a la capa de entradas (las neuronas que actúan como entrada de señales o valores externos) y la capa de salidas (las neuronas que proporcionan su salida al exterior). El conjunto de valores que se presentan a las neuronas de la capa de entradas (un valor por neurona), correspondientes a las entradas de la propia red neuronal, recibe la denominación del valor del vector de entradas.

La principal características de las redes neuronales es su capacidad de aprendizaje. Este aprendizaje consiste en el ajuste de los pesos de las conexiones entre neuronas de una forma iterativa para conseguir un efecto deseado, el de "aprender" las relaciones existentes entre pares de valores de vectores de entradas-salidas que se les suministren, o encontrar un patrón común en datos de entrada para poderlos clasificar de acuerdo a los distintos patrones [40].

A continuación se muestra un ejemplo de red neuronal artificial que se usa en WPMS (Wind Power Management System). Se compone de diferentes capas que son responsables de la percepción de la entrada, del procesamiento de acuerdo con la formación previa y de la salida de la predicción de energía. Por tanto, la principal idea consiste en relacionar las predicciones meteorológicas con la correspondiente medida de potencia de salida a fin de crear una curva de potencia multidimensional para cada sitio representativo.

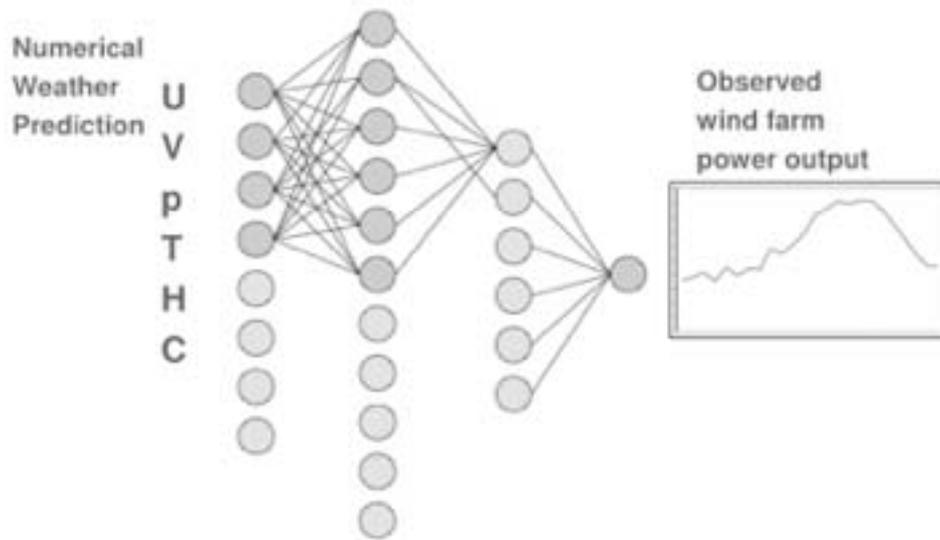


Figura 5.6: Esquema básico de red neuronal utilizado en WPMS.

Fuente: Physical Approach to Short-Term Wind Power Prediction

La principal ventaja que aportan los modelos con las redes neuronales se deriva del hecho de que no hace falta conocer la naturaleza del conjunto de datos que se requiere presentar, sino que la propia red neuronal, a través del proceso de entrenamiento, recoge las características esenciales del conjunto de datos a representar. Otras ventajas se pueden citar son las indicadas seguidamente.

- No linealidad: el comportamiento no lineal de las funciones de activación de las neuronas posibilita que las redes neuronales puedan actuar como aproximadores universales de funciones no lineales.
- Son adaptables a la evolución de cualquier tipo de representación de datos sin más que volverlas a entrenar.
- Presentan una menor dependencia del conocimiento de los “expertos” en el desarrollo de modelos.

Como desventajas se pueden citar las señaladas seguidamente.

- Necesidad de disponer de gran cantidad de datos: el entrenamiento de las redes neuronales con muchas entradas exige un número elevado de valores del vector de entradas y del correspondiente valor del vector de salidas. Hay muchos problemas en los que resulta difícil obtener gran cantidad de datos, necesaria para que la red neuronal sea entrenada adecuadamente.
- Posibilidad de que el proceso de entrenamiento conduzca a algún mínimo local.

Los modelos basados en redes neuronales artificiales se han manifestado como candidatos ideales en la aproximación de funciones no lineales.

Para el caso concreto de la predicción de la producción eléctrica en parques eólicos, como problema de característica no lineales que es, los modelos basados en redes neuronales constituyen una de las opciones, a priori, más interesantes a considerar.

5.3.2.5 Fuzzy Logic: Sistemas de inferencia difusa.

Un enfoque diferente con modelos estadísticos de predicción basado en lógica difusa ha sido desarrollado por Ecole de Mines (ARMINES), Francia, para proporcionar una predicción a corto plazo de la energía eólica.

Los modelos basados en lógica difusa, junto con los modelos basados en redes neuronales artificiales, constituyen un conjunto de herramientas de representación o modelización que pertenecen al campo conocido como "soft computing". La lógica fuzzy es una técnica para la incorporación del conocimiento estructurado humano en algoritmos eficientes.

La base del razonamiento difuso son las reglas del tipo "SI... ENTONCES...". El conjunto de reglas (base de reglas) constituye el conocimiento lingüístico que "tiene" el sistema de inferencia difuso y que le permite resolver el problema. Cada una de las reglas responde a una expresión como la reflejada en la ecuación:

$$\text{Ecuación 5.1} \quad \text{SI } x_1 \text{ es } A \text{ Y } x_2 \text{ es } B \text{ ENTONCES } y \text{ es } C$$

Donde x_1 y x_2 representan dos de las variables de entrada e y representa la variable de salida.

A , B y C son conjuntos difusos definidos en el universo de discurso de x_1 , x_2 e y , y representados por la etiqueta lingüística correspondiente. A la proposición difusa " x_1 es A Y x_2 es B " se le llama antecedente o premisa y a la proposición difusa " y es C " se le

llama consecuente o conclusión. Una regla expresa un tipo de relación entre, A, B y C que se denomina implicación lógica.

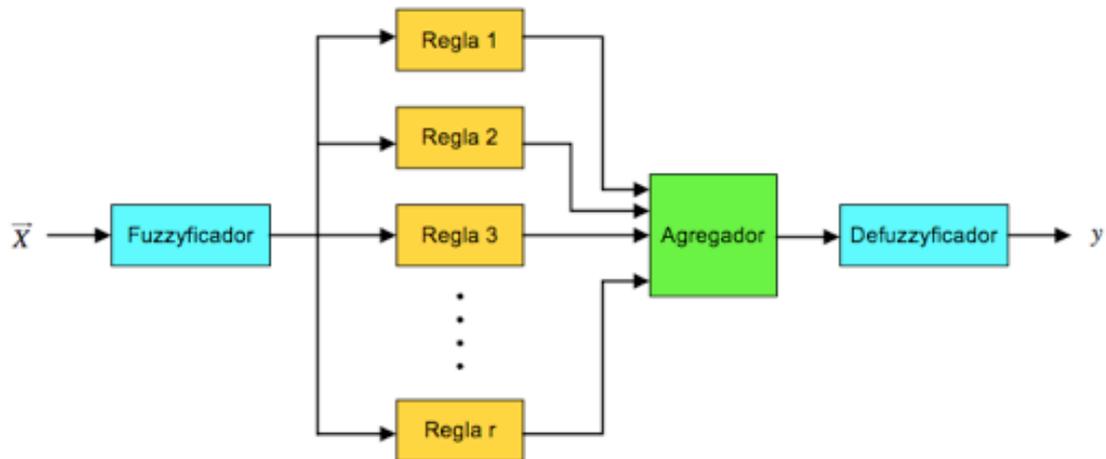


Figura 5.7: Estructura de un sistema de inferencia difusa.

Fuente: Universidad de La Rioja

El bloque agregador manipula los resultados de las distintas reglas para producir un resultado, todavía en términos difusos, que el bloque “defuzzyficador” se encarga de convertir en una variable numérica.

Existen varios tipos de sistemas de inferencia difusa que difieren, fundamentalmente, en la parte consecuente de las reglas, el método de agregación y la correspondiente “defuzzyficación” posterior. Entre esos sistemas se pueden citar los de Mandani, Takagi-Sugeno, y Tsukamoto.

La principal ventaja que reportan los modelos basados en sistemas de inferencia difusa radica en la facilidad que representa para la mente humanada entender el propio modelo. A diferencia de los modelos basados en redes neuronales (que se comportan como una “caja negra”), en el caso de los modelos de inferencia difusa, llegar a comprender el modelo es más sencillo.

Seguidamente se indican otras ventajas:

- La posibilidad de los sistemas de inferencia difusa de integrar la irremplazable experiencia de expertos humanos. Esta experiencia se puede implementar fácilmente en las reglas del tipo “SI... ENTONCES...”.
- Los sistemas de inferencia difusa pueden integrar términos lingüísticos en el razonamiento.

—

Los sistemas de inferencia difusa presentan limitaciones: desde el principio se deben fijar las reglas que establecen el funcionamiento del sistema, y, en ocasiones, un cambio de condiciones puede requerir la creación de un nuevo sistema de inferencia difusa (puede aparecer una imposibilidad en adoptar el sistema al cambio de condiciones).

Los sistemas basados en sistemas de inferencia difusa han mostrado, a lo largo de los últimos años, una aplicabilidad tan universal como la de los modelos basados en redes neuronales artificiales. Comparten con estas la capacidad de aproximación de funciones no lineales, y les aventajan en la posibilidad de que el diseñador pueda adaptar el modelo de predicción debido a su mayor sencillez conceptual.

La predicción de la producción eléctrica en parques eólicos utilizando sistemas de inferencia difusa se realiza en función del horizonte de predicción. En función del horizonte de predicción, se usan (o no) los últimos valores de la variable a predecir (normalmente la potencia eléctrica generada) como entrada al sistema de predicción. El resto de entradas corresponderá a las predicciones de un modelo atmosférico, en el caso de que estuvieran disponibles.

5.3.2.6 Conclusiones

Los modelos expuestos en este apartado constituyen los más usados en la predicción de futuros valores, y por tanto resultan muy adecuados para la predicción de la producción eléctrica en parques eólicos.

Entre las metodologías analizadas se encuentran los modelos que hacen uso de técnicas MOS, los que utilizan filtros de Kalman y los que se basan en redes neuronales o lógica borrosa. Con los modelos basados en filtros de Kalman se han conseguido reducciones del error en el pronóstico de hasta un 20% en algunos casos, especialmente para horizontes largos de predicción. En cuanto a los errores de predicción, cabe recordar que los errores en la predicción numérica del modelo meteorológico global o de área limitada representan la principal fuente de error. Por otro lado, en lo que respecta a los modelos basados en técnicas MOS, se ha avanzado

en la selección de los predictores y en la utilización de los componentes principales para mejorar las predicciones.

Estos modelos se han revelado además como una herramienta casi indispensable como etapa final de un downscaling físico, especialmente en situaciones de terreno complejo, pudiendo reemplazar a las modelizaciones físicas de alta resolución que requerirían un mayor coste computacional.

Finalmente, los modelos basados en redes neuronales han permitido el desarrollo de curvas bidimensionales del parque al introducir, no solo la influencia de la velocidad de viento, sino también su dirección. Igualmente, se han mostrado como herramientas eficaces para la predicción de la producción a partir de las predicciones numéricas de un modelo regional o área limitada.

5.3.3 Comparación de modelos.

Se pueden comparar alguno de los modelos citados anteriormente [17]:

- Parque Alaiz (España): Este parque se caracteriza por un terreno muy complejo.

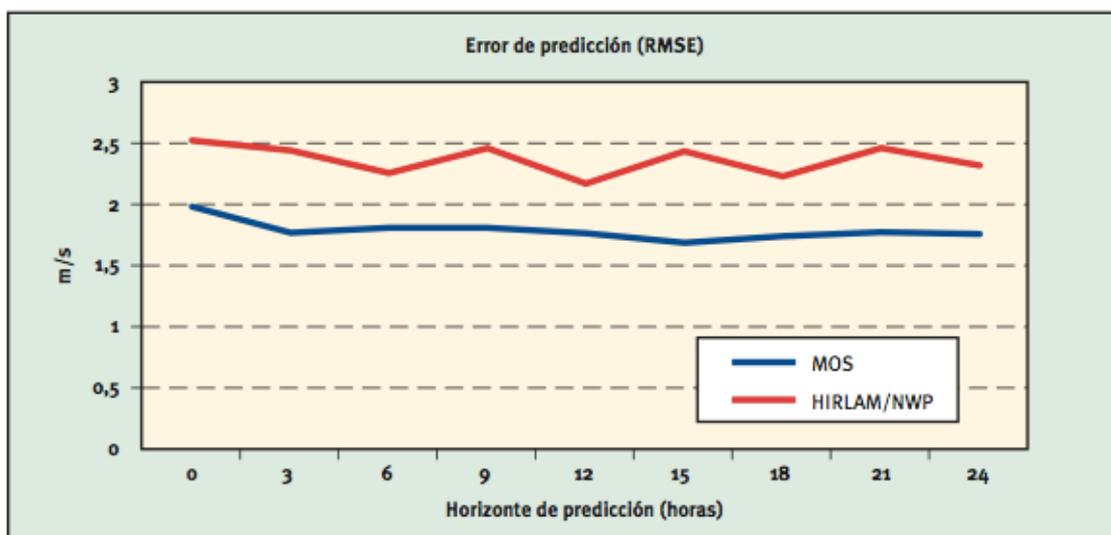


Figura 5.8: Mejora del error de predicción (RMSE) de la velocidad de viento en el parque de Alaiz.

Fuente: Proyecto ANEMOS

En la figura 5.8 se observa el error de predicción de la velocidad de viento que presenta el modelo atmosférico HIRLAM/NWP y MOS.

El downscaling estadístico (MOS) resulta especialmente eficaz en parques con orografía compleja, tal como muestra la anterior figura para el parque de Alaiz (Navarra). Éste downscaling estadístico disminuye el error por debajo de 2m/s.

- CENER (Centro Nacional de Energías Renovables) llevó a cabo simulaciones con MM5 en conjunción con un modelo de dinámica de fluidos (CFD) con el objeto de aumentar la resolución de las predicciones. Los modelos computerizados de dinámica de fluidos (CFD) son un tipo de modelos que no requieren de muchas parametrizaciones, ya que permiten resolver las ecuaciones completas del movimiento para parcelas muy pequeñas. La resolución de las predicciones de estos modelos suele ser de algunos pocos metros. La figura inferior muestra la comparación entre los errores obtenidos utilizando las salidas del modelo MM5:

◆ MM5: Modelo atmosférico de mesoescala.

■ MM5 + CFD: Modelo atmosférico de mesoescala más un modelo acoplado de dinámica de fluidos (CFD).

□ LocalPred: Modelo MOS denominado LocalPred.

● MM5 + CFD + MOS (solo variables CFD).

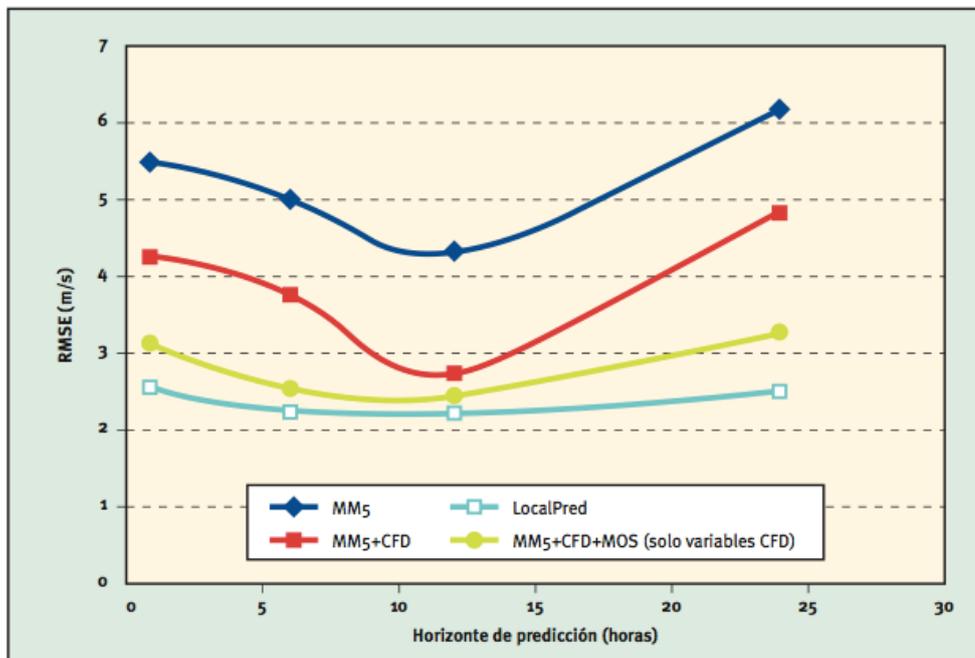


Figura 5.9: Errores (RMSE) de las predicciones de viento para Alaiz de los modelos:

MM5, MM5+CFD, MM5+LocalPred, MM5+CFD+MOS.

Fuente: Proyecto ANEMOS

Se puede apreciar el efecto de la aplicación directa de un modelo MOS sobre las salidas del MM5, así como la contribución del modelo CFD, con y sin aplicación del MOS. En general, en el marco del proyecto [17] se concluye que la utilización de un modelo CFD mejora los resultados de la predicción. Sin embargo, los resultados obtenidos son equivalentes a los que se obtendrían con la aplicación del MOS.

5.4 La herramienta de predicción SIPREÓLICO

La herramienta Sipreólico, fruto de la colaboración entre la Universidad Carlos III de Madrid y Red Eléctrica de España, está en funcionamiento on-line desde febrero de 2002, y fue desarrollada con la intención de mitigar el impacto de la generación eólica instalada en el territorio peninsular español sobre la operación del sistema eléctrico [19].

Empleando métodos estadísticos, proporciona predicciones a corto plazo, hasta 48 horas, de la producción eólica para cada una de las unidades de predicción recogidas en una tabla de parques. Para ello se vale de previsiones meteorológicas obtenidas de modelos atmosféricos y de medidas de potencia registradas en las unidades de predicción (Figura 5.10).

Las unidades de predicción pueden representar parques individuales o pequeñas agrupaciones de parques cercanos que vierten su potencia a un mismo nudo y que, por tanto, comparten la información de ubicación geográfica y de medidas de generación eléctrica.

Posteriormente al cálculo de predicciones para los parques, se obtienen predicciones agrupadas por zonas, empresas, nudos, etc, mediante la agregación de las predicciones de varias unidades de predicción. Del mismo modo, también se calcula la predicción de potencia total peninsular como la suma de las predicciones de todos los parques. Todas las predicciones, individuales o agregadas, se pueden reportar

mediante informes de salida adaptados a las necesidades del usuario final de las predicciones.

5.4.1 Datos de entrada

Sipreólico calculará las predicciones usando modelos estadísticos en base al uso de unos datos de entrada, que son la previsión de viento en el emplazamiento o proximidades de los parques, y la potencia en tiempo real registrada en los mismos.

Dado que Sipreólico calcula predicciones para cada una de las unidades de predicción de forma individual, necesita una tabla o base de datos que contenga los datos estáticos de los parques. Esta tabla, entre otra información, contiene la ubicación de los parques en coordenadas de longitud y latitud, que será usada para asignarles predicciones de viento, y la potencia eólica total instalada en los mismos.

Las medidas de potencia en tiempo real consisten en medias cuartohorarias o veinteminutales de la potencia generada por los parques eólicos. Estos valores se obtienen tras el procesado de las telemidas recibidas cada 12 segundos por el centro de control de Red Eléctrica.

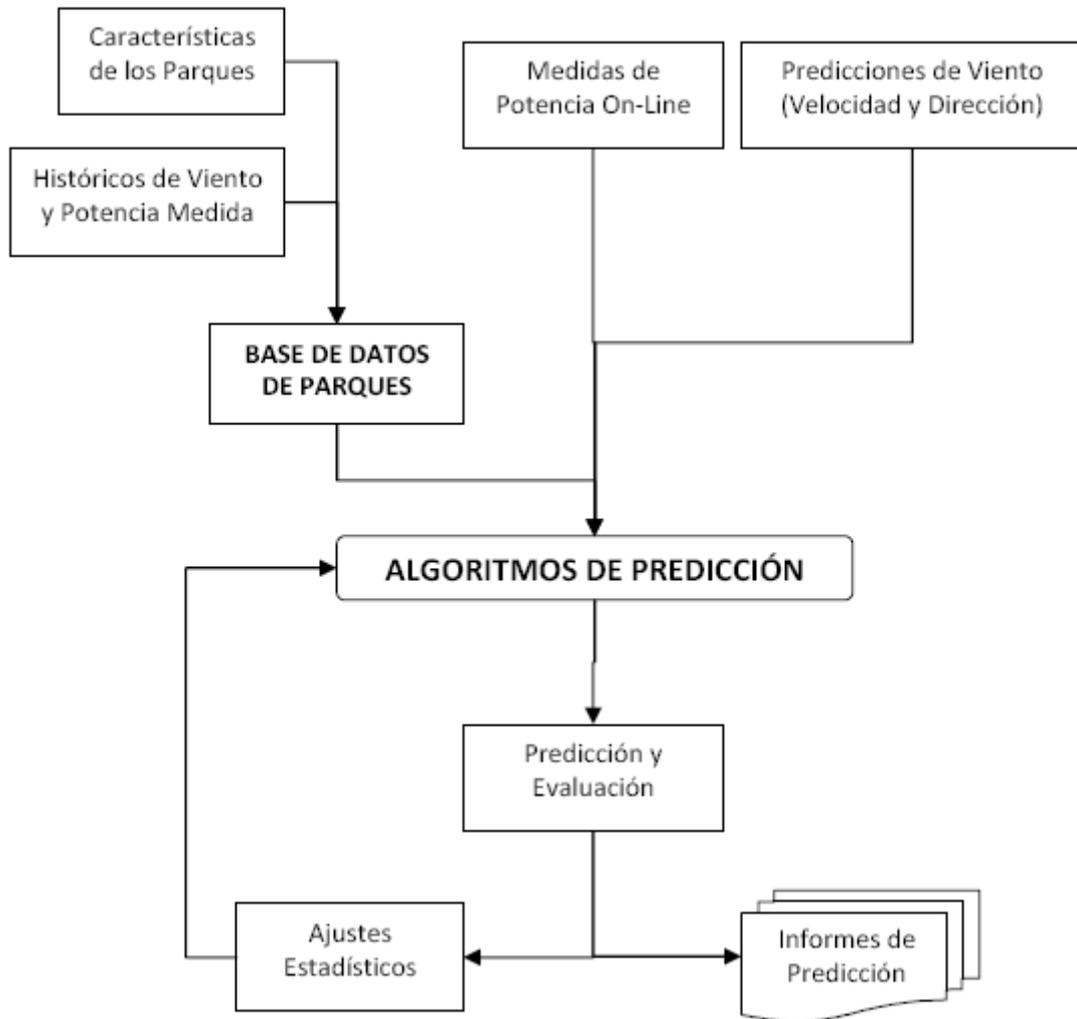


Figura 5.10: Diagrama de funcionamiento de SIPREEÓLICO

Fuente: REE

Las telemidas son las que definen el concepto de unidad de predicción, siendo en ocasiones telemidas de un solo parque, o englobando en otras ocasiones en una misma medida la agrupación de varios parques cercanos conectados a un mismo nudo y con una sola telemida común.

En la actualidad, aproximadamente el 92 % de la potencia eólica instalada en el Sistema Eléctrico Peninsular proporciona telemidas en tiempo real [20], por lo que Sipleólico puede realizar cálculos completos para la casi totalidad de los parques eólicos, con la necesidad de hacer estimaciones de predicción mediante reescalado para tan solo el restante 8 %.

Sipreólico también necesita predicciones meteorológicas para el cálculo de la predicción de potencia. Estas predicciones meteorológicas incluyen las previsiones de velocidad y dirección del viento en una serie de coordenadas geográficas distribuidas por el territorio peninsular, y cercanas a los emplazamientos de los parques eólicos.

Debido a que muchos de los parques eólicos se encuentran cercanos unos a otros, no es necesaria una predicción de viento específica para las coordenadas de cada parque, sino que se pueden compartir coordenadas de previsión de viento.

Actualmente, se utilizan previsiones meteorológicas de dos agencias: Las provenientes de la Agencia Estatal de Meteorología (AEMET), que proporciona cada 6 horas predicciones de velocidad y dirección del viento con un horizonte de 56 horas, calculadas por el modelo atmosférico HIRLAM de 0.16 grados de resolución espacial e interpoladas a las coordenadas de interés, y las previsiones de viento generadas cada 12 horas por el modelo atmosférico del Centro Europeo de Predicciones (ECMWF), que proporciona predicciones con un horizonte de hasta 4 días.

5.4.2 Modelos de predicción de Sipreólico

Existe una relación no lineal entre la velocidad del viento y la potencia que entregan los parques eólicos que no resulta fácilmente modelable, pues en el emplazamiento de un parque eólico existen perturbaciones que afectan a la relación entre la velocidad y la potencia, como puede ser una orografía compleja, la presencia de obstáculos o el efecto de estela dependiendo de la disposición de las turbinas, lo que hace que esta relación sea incluso dependiente de la dirección del viento.

Además, el hecho de que las curvas de potencia deban ser estimadas y construidas con predicciones de viento proporcionadas por institutos meteorológicos de no muy alta resolución, e interpoladas a coordenadas más o menos cercanas al emplazamiento de las turbinas, hace que la construcción de la curva de potencia sea aún más compleja y con mayores fuentes de error posibles.

Por otro lado, la relación existente entre potencia y viento es variable a lo largo del tiempo, siendo dependiente de otras variables como la temperatura, presión y

humedad del aire, o incluso con una componente estacional o diaria, lo que hace que sea una relación dinámica y cambiante con el tiempo.

Para poder afrontar estos problemas y situaciones posibles, la herramienta de predicción Sipreólico emplea varios modelos de predicción, que pueden clasificarse en dos tipos: paramétricos y no paramétricos.

Los modelos paramétricos son aquellos en los que la relación entre el viento y la potencia se realiza mediante modelos basados en polinomios de diferente grado y cuyos coeficientes se estiman de forma recursiva. En Sipreólico estos modelos incluyen una componente autorregresiva para recoger la inercia de las variables, y otras componentes para tener en cuenta la velocidad y dirección del viento.

También se utilizan modelos no paramétricos. En este tipo de modelos, la curva que relaciona la potencia y el viento no es prefijada de antemano, sino que es estimada con la información que proporcionan las observaciones próximas a cada punto de la relación mediante un suavizado.

Sipreólico cuenta con ocho modelos diferentes, paramétricos y no paramétricos, agrupados en cuatro bloques que recogen las distintas posibilidades que se plantean en cuanto a la estimación de la relación entre potencia y viento, y enfocados tanto a horizontes de muy corto plazo como para horizontes de corto plazo.

El primer bloque de modelos (M1 y M2) son predictores univariantes autorregresivos, es decir, solamente interviene la potencia medida en el parque. El predictor es una ecuación que relaciona el valor futuro de potencia con valores recientes de la energía medida.

La segunda categoría de modelos (M3 y M4) tienen en cuenta, además de la serie de potencia medida para la parte autorregresiva, la información de la velocidad prevista del viento. Esta velocidad se puede incluir mediante polinomios de diferente orden.

El tercer bloque de modelos (M5 y M6) emplea la información de la dirección del viento previsto, además de la información de potencias medidas y predicciones de

velocidad de viento de los modelos de la segunda categoría mencionada, también con la posibilidad de incluir la velocidad mediante polinomios de diferente orden.

El último bloque (M7 y M8) lo forman modelos que incluyen una estimación no paramétrica de la curva de potencia usando la información de la velocidad y dirección prevista del viento, y también pueden tener una componente autorregresiva basada en medidas de potencia.

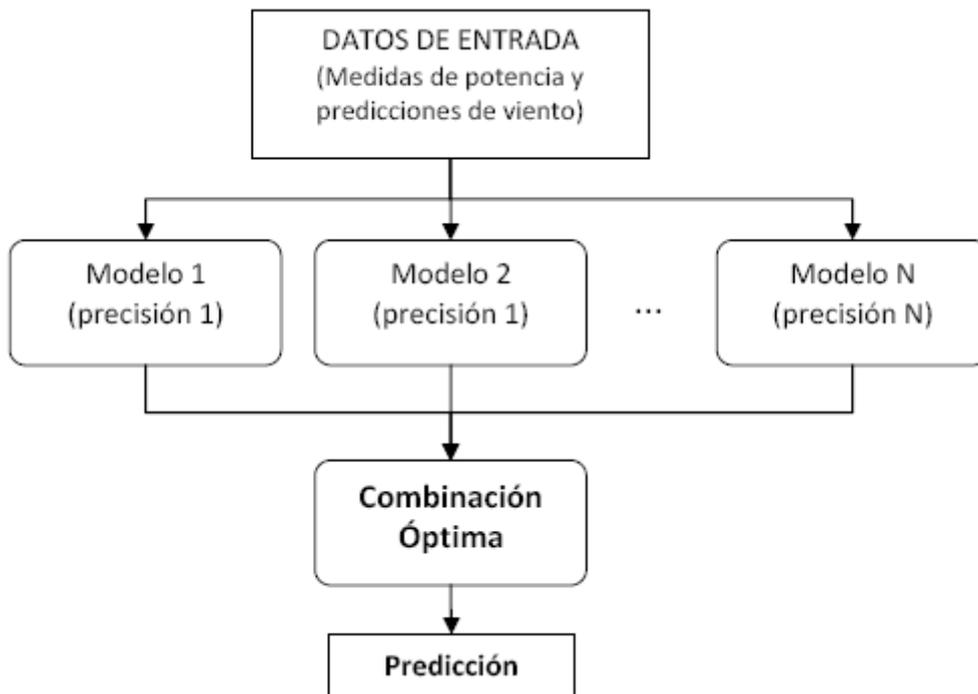


Figura 5.11: Esquema del módulo de predicción de Sipleólico Fuente: REE

La estimación de los parámetros de los modelos se hace de forma adaptativa, ya que las curvas que relacionan la producción eólica y el viento son variables en el tiempo en función de circunstancias cambiantes como la situación meteorológica. Por ello, los modelos y sus parámetros no pueden considerarse fijos y deben adaptarse en el tiempo en función de la nueva información de que se disponga. Además, los parámetros serán distintos en función del horizonte de predicción.

Por tanto, cada vez que se recoge nueva información, como velocidades de viento o medidas de potencia, se actualizan los parámetros de los diferentes modelos. Esta adaptación se realiza mediante un procedimiento óptimo de elección del grado de velocidad de ajuste y de la flexibilidad de la adaptación a los nuevos datos [21].

La predicción final se obtiene combinando las predicciones generadas por los distintos modelos (Figura 5.11). A medida que se van recopilando datos, los diferentes modelos tendrán una precisión diferente que será la que determine su peso en la predicción final para cada horizonte [22].

5.5 El proyecto ANEMOS

En 2002 comenzó el proyecto ANEMOS [24], dentro del quinto programa marco de la Unión Europea, liderado tanto por entidades de investigación del ámbito de la predicción eólica e institutos meteorológicos, como por usuarios finales de las predicciones, operadores de sistema y autoridades reguladoras, de un total de siete países: Francia, Irlanda, España, Alemania, Grecia, Dinamarca y Reino Unido.

Su objetivo fue desarrollar una plataforma de predicción eólica que integrase las bondades de todos los métodos de predicción existentes hasta el momento, basados tanto en modelos físicos como estadísticos, con el objetivo de dar predicciones para parques situados tanto en tierra firme como en el mar (off-shore), y en todo tipo de emplazamientos independientemente de la complejidad de la orografía [25].

El horizonte de predicción establecido es de 48 horas, pues es el horizonte temporal habitualmente utilizado por los operadores del sistema eléctrico para la planificación de la generación de energía, aunque se contempla la predicción hasta 7 días como herramienta de utilidad para programar labores de mantenimiento en parques o instalaciones. En cuanto a alcance espacial, abarca tanto predicción de parques individuales como predicción regional o nacional. También incluye incertidumbre en la predicción y estimación de riesgo.

El proyecto ANEMOS fue el primer banco de pruebas de varios sistemas de predicción que ya estaban funcionando en varios países europeos, comparando los sistemas AWPPS, Prediktor, WPPT, Previento, LocalPred, Sipreólico, y los modelos de RAL, ARIA y NTUA [30], utilizando para la comparación los protocolos de evaluación descritos en [30].

Para ello, se tomaron como casos de estudio algunos parques localizados en España, Alemania, Dinamarca, Irlanda, Grecia y Francia, incluyendo incluso algún parque offshore. La selección de parques incluye así emplazamientos en terrenos llanos, complejos y muy complejos.

Se propusieron varios sistemas de predicción meteorológica en los emplazamientos de los parques eólicos, entre ellos HIRLAM, SKIRON, ALADIN o DM, y también se tuvo en cuenta el uso de información meteorológica de alta resolución, como la obtenida del modelo de meso-escala MM5, para ser comparada con los modelos macro-escalares, más globales y de menor resolución. Se comprobó que se pueden obtener mejores predicciones de potencia eólica si se combinan varias fuentes de viento, y además que el uso de modelos de mayor resolución proporcionaba mejoras en la predicción para los parques situados en los terrenos especialmente complejos.

En los resultados del estudio, se comprobó que el valor medio del Error Medio Absoluto de las predicciones de los modelos para un horizonte de 12 horas oscila entre el 10% y el 21% [30], dependiendo de si se trata de un parque eólico ubicado en terreno llano o en el mar, o si está situado en un terreno montañoso complejo. En [27-29] se puede encontrar una relación más detallada de los resultados de los modelos estadísticos, físicos y de predicción offshore.

También se comprobó que, de entre los modelos de predicción comparados, ninguno era claramente mejor que los demás en todos los horizontes. Por eso, la plataforma de predicción ANEMOS incluye varios módulos y funciones de predicción. Replicando la estructura de combinación de Sipleólico, en la plataforma ANEMOS se combinan las predicciones de los distintos modelos de forma óptima en dos etapas para obtener la mejor predicción para cada horizonte, aprovechando las bondades de cada modelo de predicción independiente que tiene integrado [23].

5.6 Descripción y características de los modelos de predicción existentes

En la práctica pocos modelos de predicción utilizan sólo métodos estadísticos o físicos. Los modelos típicos de predicción utilizan de forma simultánea ambos métodos (físicos y estadísticos). En el cual, para entrenar al sistema de las condiciones locales, utilizan los resultados de la predicción numérica del tiempo como variables de entrada así como los datos históricos y teorías estadísticas.

Todos los modelos se basan siempre en un esquema similar que se presenta en la figura siguiente [31]:

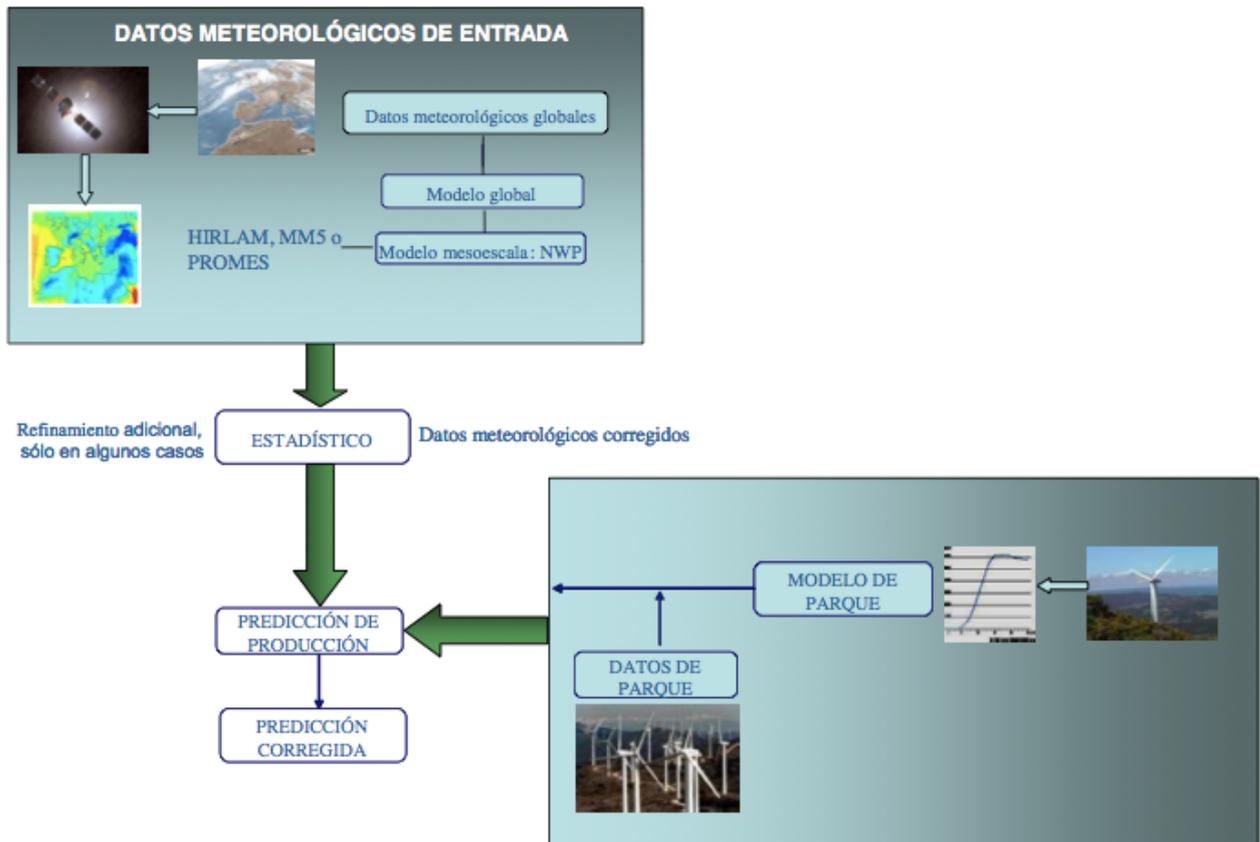


Figura 5.12: Esquema de los modelos de predicción. Fuente: AEE

En general, todos los predictores parten de las predicciones sobre la evolución de la atmósfera que les suministran los modelos numéricos (NWP) de por ejemplo: el GFS (Global Forecast System) gratuito, del Gobierno americano, el European Center for Medium Range Forecast (ECMWF) o el Instituto Nacional de Meteorología (INM); o bien una combinación de algunos o todos ellos.

A partir de esas predicciones, se pueden presentar dos tipos de predictores:

- Los que refinan los datos mediante un modelo numérico adicional de predicción como MM5 o PROMES para posteriormente realizar un “downscaling” estadístico que es lo que se conoce como Modelización físico/estadística.
- Los que parten directamente de las salidas de los modelos numéricos de los centros meteorológicos, para realizar solamente un “downscaling” estadístico. De entre estos los hay a su vez de dos tipos de modelizadores:
 - Los que realizan la previsión del viento y calculan la producción a partir de la curva o modelo del parque.
 - Los que a partir de una configuración atmosférica concreta determinan la producción de los parques, sin pasar por los datos de viento.

En general, el horizonte de predicción va de 6 horas (que es el tiempo mínimo necesario para recoger los datos y realizar el postproceso de la información) a 240 horas, aunque normalmente se limite a 42 horas debido a los importantes errores más allá de ese plazo.

Para el muy corto plazo se utiliza el modelo persistente, que mantiene la producción de una hora, durante las horas siguientes, o bien se utilizan técnicas de series temporales para el ajuste del modelo que luego predicen basado en la información de contorno del parque.

A continuación se explicará brevemente cada uno de los modelizadores que utilizan los parques.

5.6.1 Aeolis

AEOLIS FORECASTING SERVICES es una consultora independiente que ofrece servicios a todo comercio e industria relacionado con el tiempo, el sector de energía en especial [32].

Diariamente y para diferentes regiones en Europa, Aeolis Forecasting Services ofrece una previsión de producción eólica nacional. En la figura se puede apreciar las previsiones de los días anteriores (en rojo) en comparación con la producción actual (azul). La previsión se renueva cada hora.

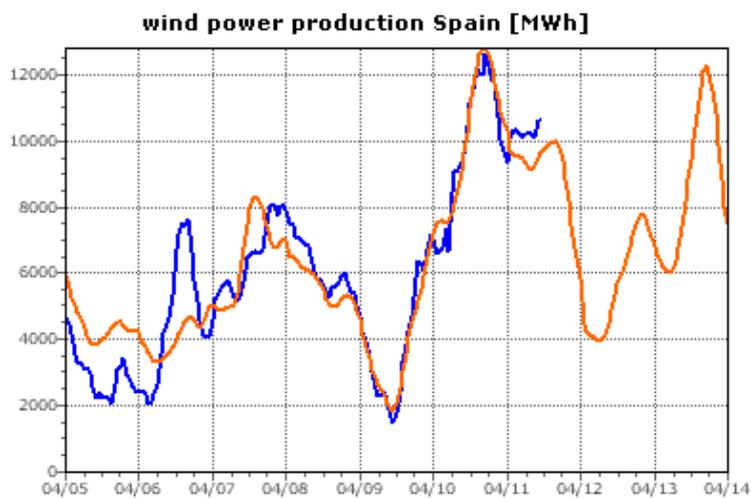


Figura 5.13: Predicción de producción eólica nacional.

Fuente: Aeolis Forecasting Services

La previsión 'day-ahead' nacional es uno de los servicios que Aeolis Forecasting Services ha desarrollado para apoyar al sector de la energía eólica. Un creciente número de empresas de energía ya está aprovechando estos servicios operacionales para crear ventajas competitivas en los mercados de energía.

Aeolis utiliza un modelo físico del parque al que ajusta a diferentes niveles por medio de estadísticos históricos para hacer frente a variables desconocidas y otras posibles desviaciones del comportamiento real.

Para ello, Aeolis ha desarrollado el sistema Scirocco. Scirocco se mejora continuamente analizando la relación entre la previsión eólica y la producción actual. Estas relaciones se utilizan para optimizar el modelo y generar directamente una previsión eólica acertada.

El predictor de producción eólica avanzado Scirocco se adapta a las circunstancias de la geografía local y a las características del parque. Los errores sistemáticos del modelo meteorológico usado (puede ser cualquier modelo apropiado) serán reconocidos y corregidos. Cuando exista un histórico de generación es posible calibrar Scirocco antes de su puesta en marcha operativa.

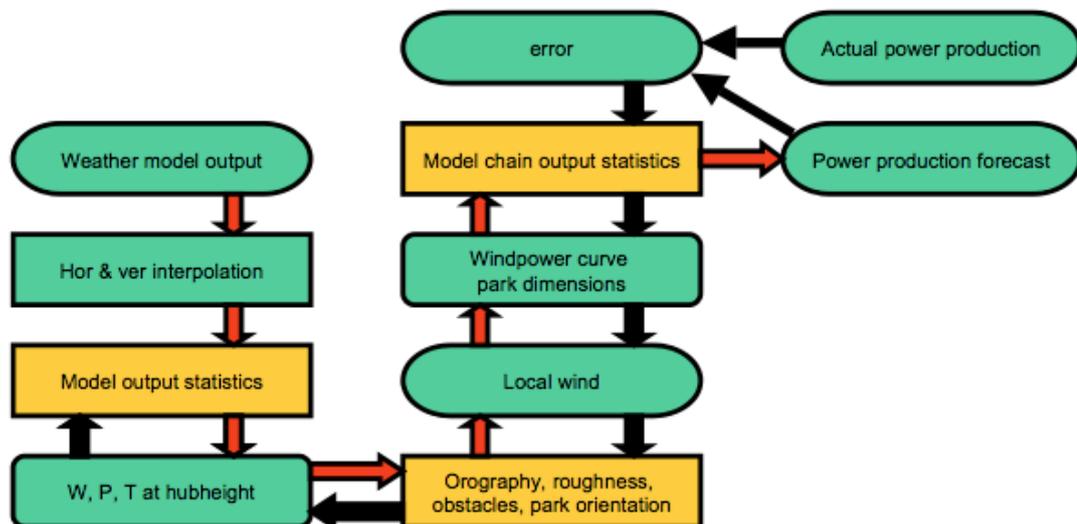


Figura 5.14: Características del modelo Aeolis.

Fuente: Aeolis

Las predicciones de producción de potencia de Scirocco son el resultado de un número de pasos consecutivos encadenados. Algunos de los pasos incluyen la aplicación de procedimientos matemáticos y físicos conocidos. Para hacer frente a variables desconocidas y procesos menos entendidos, se han introducido tres esquemas de ajuste en la cadena del modelo representados por las cajas amarillas. El ajuste de estos esquemas se calibra a través de retropropagación a lo largo de toda la cadena del modelo. La diferencia entre la potencia predicha y la real define el error,

que se realimenta al modelo y se usa para ajustar todos los parámetros en los esquemas de ajuste que han contribuido al error.

Scirocco puede ser alimentado con diferentes modelos numéricos meteorológicos (NWM) como Hirlam, ECMWF, NCEP y MM5. Todos los NWM poseen sus propios errores característicos dependientes de la estación del año, hora y horizonte de predicción. Scirocco utiliza el error en la predicción de potencia eólica para ajustar la salida directa del modelo NWM para esos errores sistemáticos a través de la retropropagación. El esquema de ajuste 'Model Output Statistics' realiza esta tarea.

El viento local se calcula de los parámetros meteorológicos ajustados resultantes en los puntos adyacentes de la parrilla usando un esquema de ajuste combinado de la orografía local y la desigualdad del terreno (incluyendo obstáculos y orientación del parque). Comenzando por un terreno plano y sin perturbaciones Scirocco utilizará el error en la producción eólica para corregir ambos esquemas de ajuste separadamente a través de la retropropagación.

La producción de potencia se puede calcular del viento local utilizando las curvas de potencia y las dimensiones del parque. Para hacer frente a las características del parque y las turbinas se realiza una última modificación utilizando el módulo 'Model Chain output statistics'.

Empezando por una configuración ideal, Scirocco devuelve una predicción de potencia directa de las salidas del modelo numérico meteorológico. El error en la predicción se realimenta al modelo y se realizan ajustes para reducirlo. De esta manera, Scirocco se ajusta a las circunstancias locales y los errores sistemáticos de los modelos numéricos utilizados.

El horizonte de predicción depende del modelo numérico utilizado. Con ECMWF es posible realizar una predicción de hasta diez días. Se debe tener en cuenta que la precisión de la predicción decaerá después de los primeros tres o cuatro días. En combinación con Hirlam, la predicción alcanza desde 15 minutos hasta 45 horas.

5.6.2 Casandra

CASANDRA ENERGY SERVICES, S.A. ha desarrollado, en colaboración con prestigiosos científicos españoles, un sistema de predicción de producción eólica que combina un modelo numérico de mesoescala de alta resolución con las más avanzadas técnicas de ajuste estadístico y modelización de parques eólicos [33].

El modelo de predicción Casandra ha sido implantado en varios parques en España, obteniéndose resultados óptimos incluso en parques de orografía muy compleja.

Este modelo de predicción se ha desarrollado con la colaboración de Gamesa Energía, Recursos Naturales Barlovento y MOMAC grupo perteneciente a la Universidad de Castilla-La Mancha.

El sistema de Predicción Casandra esta basado en el modelo mesoescalar PROMES anidado en el modelo global del National Center for Environmental Prediction. Una vez obtenida la predicción de viento se introduce en un modelo estadístico para obtener mediante técnicas de downscaling el viento concreto para cada parque y se introduce en el farm model que trasforma dicho viento en producción, teniendo en cuenta diversos factores como la orografía detallada y el tipo de aerogeneradores.

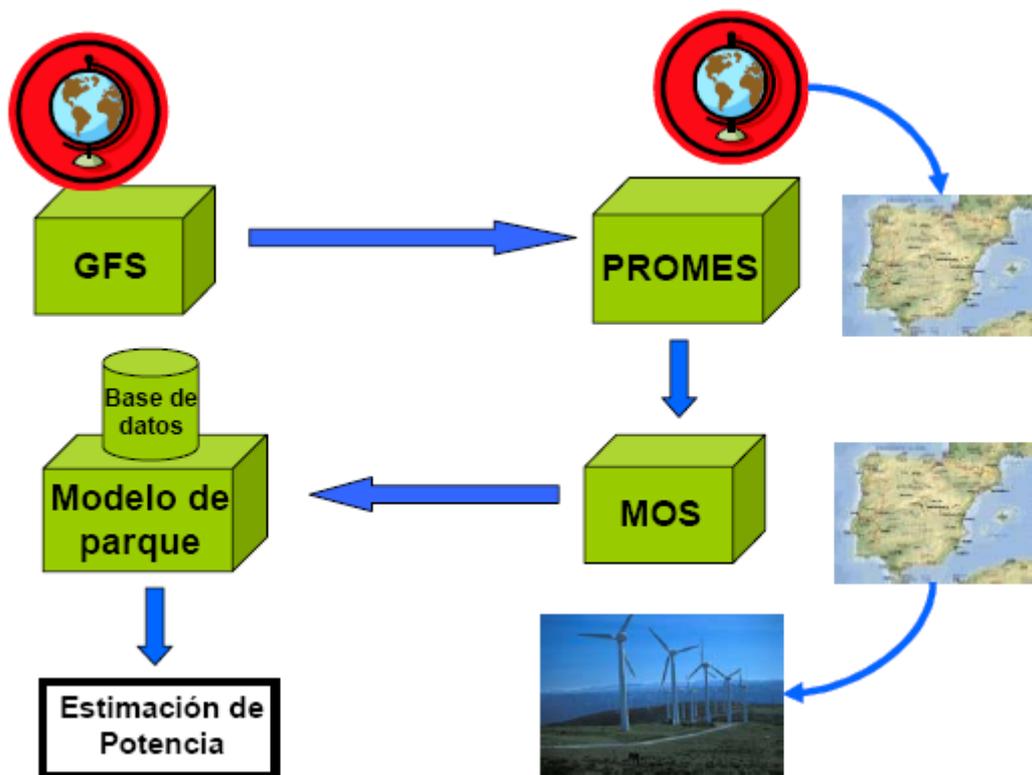


Figura 5.15: Esquema de funcionamiento del modelo Casandra. Fuente: Casandra

GFS DATA:

Las predicciones iniciales se obtienen a partir del GFS (Global Forecast System) desarrollado y utilizado por el NCEP-NOAA (EE.UU.). El modelo se ejecuta cada 6 horas.

MODEL PROMES:

Una característica importante del sistema actual es que no necesita la entrada externa de un modelo de mesoescala, ya que incluye el uso de un modelo meteorológico de mesoescala (PROMES, el acrónimo en español de "PRONósticoMESoescala"). Este modelo ha sido desarrollado por los miembros del grupo de investigación MOMAC.

PROMES es un modelo de ecuaciones primitivas, el cual es hidrostático y totalmente compresible. En el sistema de predicción del viento presente, el modelo se ejecuta en una resolución horizontal de 15 Km.

MODELO DE REDUCCIÓN DE ESCALA ESTADÍSTICA (MOS):

Con el fin de corregir los errores sistemáticos en las predicciones de los modelos de mesoescala y proporcionar información relacionada con los procesos de la sub-red (de menos de 15 km en este caso), se utiliza una técnica basada en las estadísticas de salidas de modelos (MOS). Nos permite obtener un análisis de los vientos dominantes.

MODELO DE PARQUE EÓLICO:

El modelo de parque eólico proporciona una curva de potencia del parque eólico. Los datos de parques eólicos incluyen los datos de mástiles meteorológicos (presión, temperatura, velocidad y dirección del viento), los datos de la turbina eólica (potencia, velocidad del viento en las góndolas, alarmas e incidencias) y operaciones de parques eólicos como las actividades de mantenimiento programadas. Una parte importante es el control de calidad de los datos del parque eólico, con el fin de eliminar los errores de SCADA y de los datos. Diferentes curvas de potencia se preparan utilizando un método de contenedores para los diferentes sectores de la dirección. De este modo, los efectos orográficos y las pérdidas de energía por efecto estela son considerados.

En funcionamiento, el modelo recibe las predicciones meteorológicas de MOS y datos de parques eólicos en línea y proporciona un valor al WFP (Wind farm production).

PREDICCIONES PROBABILÍSTICAS PARA LA PRODUCCIÓN DE ENERGÍA POR HORA:

El sistema de predicción ofrece como producto final un pronóstico de la producción total por hora de energía eólica en el parque eólico considerado, con niveles de confianza. El sistema de predicción en su conjunto se ejecuta en aproximadamente 3 horas, por ejemplo, para los datos de las GFS que están disponibles a las 5 UTC, las previsiones de producción de energía eólica están dispuestos alrededor de las 8 UTC.

5.6.3 CENER

El Centro Nacional de Energías Renovables (CENER) es un centro tecnológico especializado en la investigación aplicada, el desarrollo y fomento de las energías renovables. Cuenta con una alta cualificación y un reconocido prestigio nacional e internacional [34].

Se trata de una Fundación que inició su actividad en 2002, cuyo Patronato está compuesto por el Ministerio de Industria, el Ministerio de Ciencia e Innovación, Ciemat, y el Gobierno de Navarra.

CENER define la predicción como la estimación de la producción de una instalación eólica en un horizonte cercano de cara a facilitar la gestión de la energía al operador del sistema eléctrico. Para ello, CENER dispone de un software y metodología propios y en continuo desarrollo. Además de aportar la información sobre la predicción en tiempo real para un gran número de parques eólicos en el mercado español, CENER participa en diversos proyectos de financiación pública (ANEMOS.plus, POW'WOW).

El modelo de predicción LocalPred, desarrollado conjuntamente entre CIEMAT y CENER, comprende:

Predicción meteorológica propia basada en modelos de mesoescala (SKIRON y MM5).

Posibilidad de utilizar la predicción del Instituto Nacional de Meteorología de forma complementaria.

Corrección estadística tipo MOS para adecuar la predicción a la ubicación concreta de cada parque.

Combinación de las distintas predicciones disponibles (procedentes de los distintos modelos meteorológicos) para cada parque eólico. Esta metodología se conoce como “ensemblemultimodelos”.

- Predicción para el mercado diario.
- Predicción para mercados intradiario.
- Predicción para la opción de tarifa fija.
- Backup de seguridad para garantizar el envío de predicciones.

CENER utiliza la información proporcionada por el modelo global GFS como condiciones de contorno del modelo de mesoescala. La ejecución de dicho modelo es a través de anidamiento, realizando así un downscaling dinámico para aumentar la precisión de la estimación. Posteriormente, se eliminan efectos locales a través de un downscaling estadístico. De este modo, se obtienen predicciones locales del campo de viento. Finalmente, a través de la modelización de potencia del parque se obtiene la predicción de potencia.

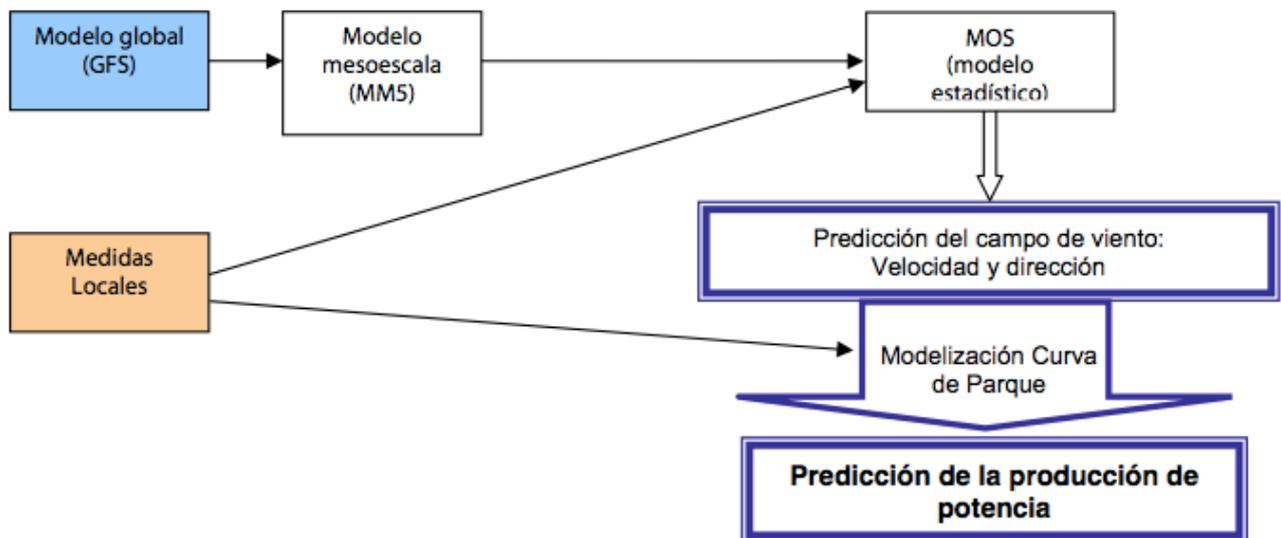


Figura 5.16: Características del modelo CENER.

Fuente: CENER.

5.6.4 MeteoLógica

MeteoLógica S.A, desde 1997, ha trabajado en diferentes proyectos y servicios de predicción que ofrece a nivel mundial, con más de 350 clientes en 22 países. Como ejemplo, durante este periodo MeteoLógica ha sido elegido como proveedor de predicciones para más de 1.500 proyectos de parques eólicos en todo el mundo, los cuales suman un total de más de 25.000MW de potencia instalada [35].

Diariamente y para diferentes regiones en Europa, MeteoLógica ofrece una previsión de producción eólica nacional. En la figura se puede apreciar las previsiones de los días anteriores (en rojo) en comparación con la producción actual (verde). La previsión se renueva cada hora. Se observa la predicción a diez días de la generación eólica en Alemania.

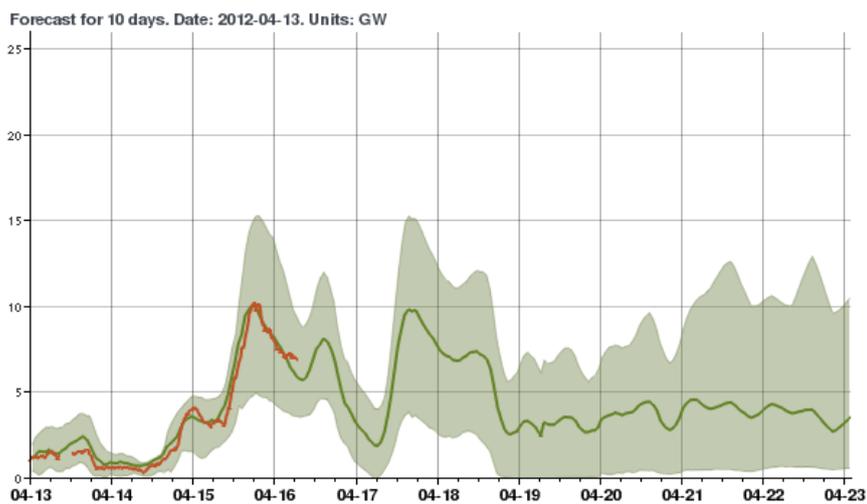


Figura 5.17: Predicción regional de generación eólica en Alemania y observaciones en tiempo real.

Fuente: MeteoLógica

Como se ha estudiado en los anteriores capítulos, los Modelos de Predicción Numérica realizan simulaciones computarizadas de la evolución de la atmósfera para los siguientes días. Son la esencial, y universalmente utilizada, herramienta de predicción meteorológica. Los Modelos de Predicción Numérica se basan en una red tridimensional que cubre la atmósfera y las capas superiores de los continentes y océanos. Mediante el uso de las leyes físicas que gobiernan la dinámica atmosférica, se

calculan los flujos de masa y energía entre puntos adyacentes de una malla. Estados futuros de la atmósfera se prevén a través de la integración temporal de estos flujos.

A pesar de su sofisticación, los pronósticos de la situación meteorológica en superficie generados por los modelos de predicción numérica todavía tienen sus limitaciones. Por ejemplo, la resolución horizontal (la distancia entre puntos de malla adyacentes) no es lo suficientemente fina para representar algunos componentes del mundo real como la topografía, que ejercen una influencia muy fuerte sobre las condiciones meteorológicas cercanas a la superficie. Otra limitación importante es que las predicciones del MPN son deterministas, lo que significa que no ofrecen un grado de incertidumbre en el pronóstico. Estas limitaciones hacen que sea esencial aplicar una técnica de post-proceso conocido como "reinterpretación" o "downscaling".

MeteoLógica recibe, varias veces al día, estos pronósticos generados por los MPN más avanzados. Estos MNP son sometidos al proceso de "downscaling" y son fusionados, utilizando tecnología propia, para obtener de manera óptima unas precisas predicciones meteorológicas en superficie.

En la última etapa, se originan las previsiones de las variables de negocio de interés. Se utilizan diferentes tipos de modelos matemáticos en este proceso de traducción. Algunos de ellos han sido completamente desarrollados por MeteoLógica, otros se han adaptado a las necesidades de la empresa a partir de modelos de dominio público.

Algunos de estos modelos incluyen leyes físicas que simulan relaciones entre variables (por ejemplo el modelo de pavimento), otros se basan en relaciones estadísticas entre variables de entrada y de salida. Todos ellos requieren una calibración especializada con los datos observados con el fin de proporcionar el máximo valor al usuario. Lo que MeteoLógica proporciona a sus clientes es esencialmente información.

Las predicciones de MeteoLógica provienen de aplicar la curva de potencia a los datos de viento obtenidos del downscaling del modelo ECMWF comparado con datos históricos en los que se registraron las mismas condiciones meteorológicas, de forma que sólo se comparan condiciones similares para extraer las predicciones.

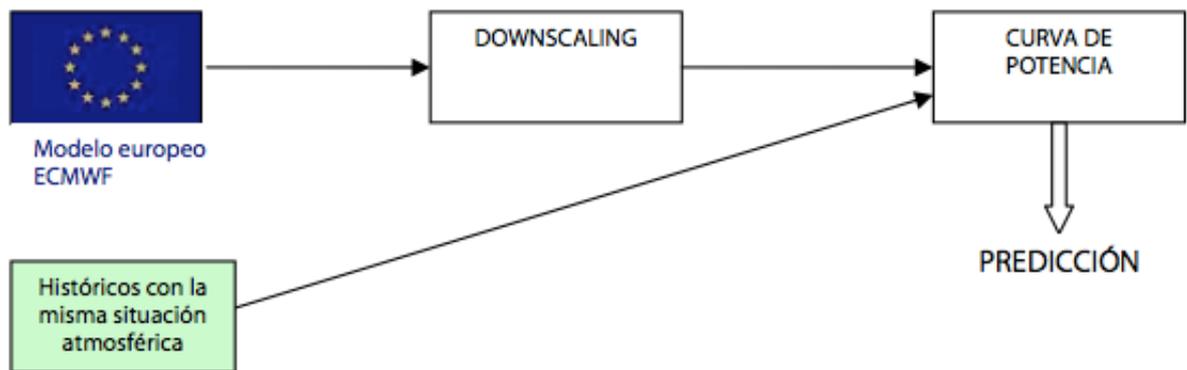


Figura 5.18: Características del modelo Meteorológica.

Fuente: Meteorológica

5.7 Otros modelos

Existen muchos modelos de predicción eólica, en el ejercicio de predicción que se comentó anteriormente [84], también se nombran otros modelos que predicen la potencia eólica de numerosos parques a nivel nacional e internacional. Estos son:

5.7.1 Aleasoft

ALEASOFT ENERGY FORECAST, nació en el año 1999 fruto del contexto de liberalización de los mercados energéticos europeos y con motivo de los resultados obtenidos en trabajos de investigación en el ámbito de la previsión energética realizados en la UPC (Universidad Politécnica de Cataluña). La UPC es socio fundador y partner tecnológico de AleaSoft [36].

Ofrece una nueva generación de modelos de previsión, desarrollados a partir de la fusión de metodologías de estadística e inteligencia artificial. Dispone de herramientas y experiencia en informática avanzada para materializar estos modelos en soluciones finales para el cliente.



Figura 5.19: Esquema general de funcionamiento AleaSoft.

Fuente: AleaSoft

Con AleaWindse obtiene previsiones a corto plazo de la producción eólica a nivel nacional, regional o para cada parque eólico.

Presenta muchas ventajas y características:

- La solución se instala a tu medida, de acuerdo a las necesidades específicas.
- El tipo de previsión puede ser: nacional, regional o para cada parque eólico.
- Trabaja con series largas, de longitud ilimitada.
- Permite obtener previsiones horarias, en tiempo real, con distintos horizontes: desde 24 horas (un día) hasta 48 horas (2 días).
- Una vez que los modelos de previsión han sido desarrollados por nuestros especialistas, la solución funciona automáticamente.
- Gracias a un esquema adaptativo que actualiza los parámetros de los modelos de forma continua, la aplicación puede ser utilizada por un usuario sin amplios conocimientos estadísticos.
- La solución se alimenta a diario con datos de fuerza y dirección del viento. La actualización de datos y la previsión puede generarse automáticamente a una determinada hora.

Este modelo presenta la particularidad de la utilización de una red neuronal para realizar el modelo del comportamiento del parque, a partir del cual, introduciendo las previsiones meteorológicas se obtendrá la predicción.

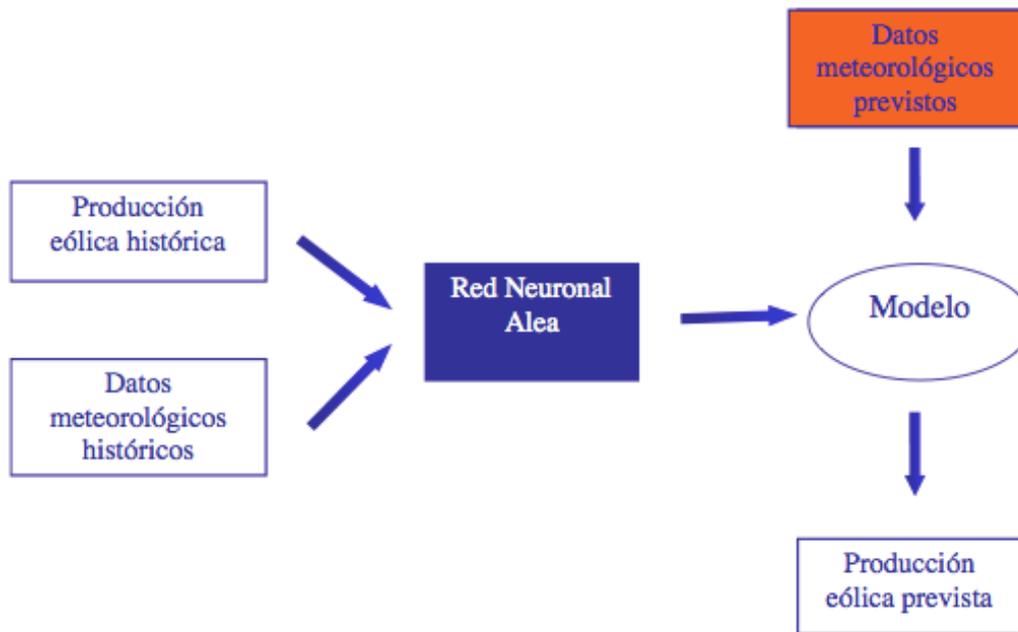


Figura 5.20: Características del modelo AleaSoft.

Fuente: AleaSoft

5.7.2 GARRAD HASSAN

El desarrollo del Garrad Hassan Forecaster empezó con un proyecto de investigación financiado en parte por el Ministerio de Comercio e Industria del Reino Unido (DTI). Los socios del proyecto para este trabajo eran Scottish Power y el Instituto Meteorológico del Reino Unido (UK Met Office). El proyecto de investigación tuvo como resultado la predicción de la producción futura de energía de dos parques eólicos del Reino Unido. Los resultados de dicho trabajo de investigación fueron muy alentadores y GH ha realizado un esfuerzo considerable en desarrollar el código basado en la investigación para llegar a un producto de software fiable [37].

Existen varios grupos de trabajo en el campo de la predicción de energía eólica y todos tienen propuestas ligeramente diferentes. Sin embargo, en todos ellos, la creación de predicciones de producción energética se realiza mediante un proceso de dos etapas. Primero, está la creación de predicciones meteorológicas específicas para el emplazamiento (para algún punto de referencia predefinido, como un mástil meteorológico en el emplazamiento). GH Forecaster puede utilizar los pronósticos de tiempo de cualquier instituto meteorológico nacional, sin estar limitado a priori a un

horizonte de tiempo en particular. Estas predicciones meteorológicas se transforman posteriormente, a través de los modelos de energía específicos del parque eólico, en predicciones de la producción de energía. Utilizando datos retroalimentados del mismo parque, el modelo crea modelos estadísticos consistentes de la meteorología específica del emplazamiento. Cada vez que un pronóstico es proporcionado por el instituto nacional, el modelo convierte dichos datos en predicciones específicas para el emplazamiento que luego son introducidas en una curva de potencia del parque eólico para obtener las predicciones de la producción de energía. GH utiliza técnicas de aprendizaje adaptativo, de tal manera que los cambios a medio y largo plazo en el emplazamiento – como cambios estacionales o topográficos – se acomodan sin necesidad de reaprendizaje.

En la figura aparece un ejemplo de serie temporal, mostrándose como el modelo transforma las predicciones del PNT (línea de puntos) para representar lo que ocurre realmente en el emplazamiento. El ejemplo dado es para un horizonte de predicción de $T + 12$ horas, para un mástil meteorológico en un parque eólico situado en terreno complejo.

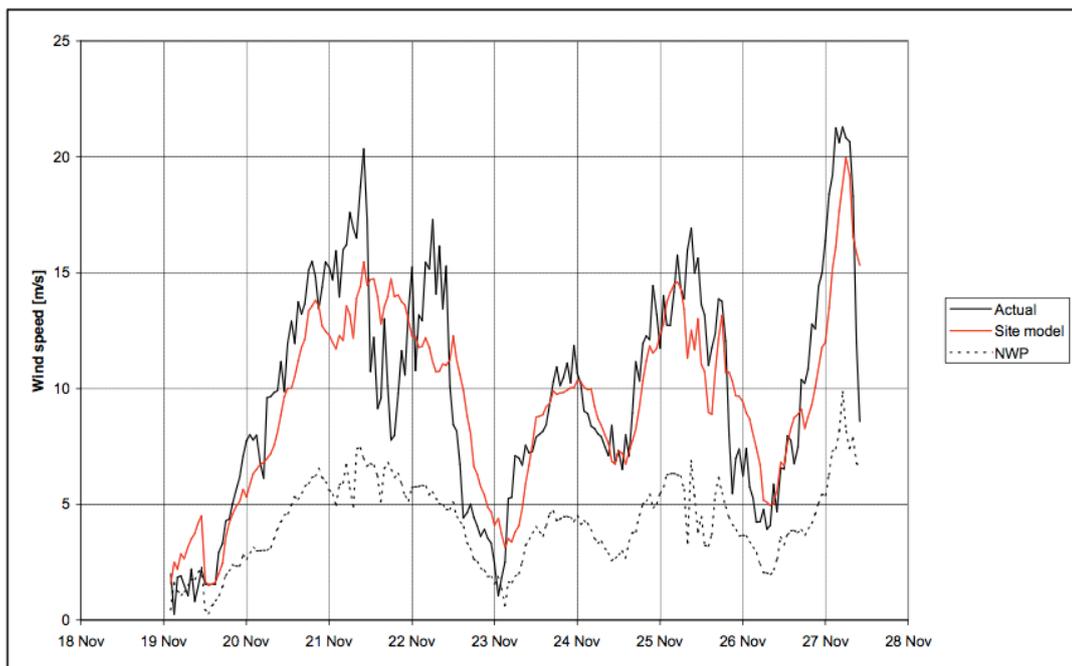


Figura 5.21: Ejemplo de serie temporal de una predicción de velocidad de viento, $T + 12$ h.

Fuente: Garrad Hassan

La serie temporal empieza el 19 de noviembre con el modelo del emplazamiento inicializado el 1 de noviembre. Se puede ver como el modelo se ha adaptado de manera mucho más precisa en menos de tres semanas.

El siguiente paso del proceso es convertir las predicciones meteorológicas de viento en predicciones de energía. La transformación de las predicciones meteorológicas en predicciones de energía constituye la segunda etapa del proceso. Esta transformación se consigue habitualmente con una matriz de energía del parque eólico, utilizando intervalos múltiples de dirección y velocidad de viento para representar la producción de energía del parque. Debería remarcarse que el método que produce esta matriz de energía es decisivo si no se quiere introducir en esta fase mayor incertidumbre en las predicciones.

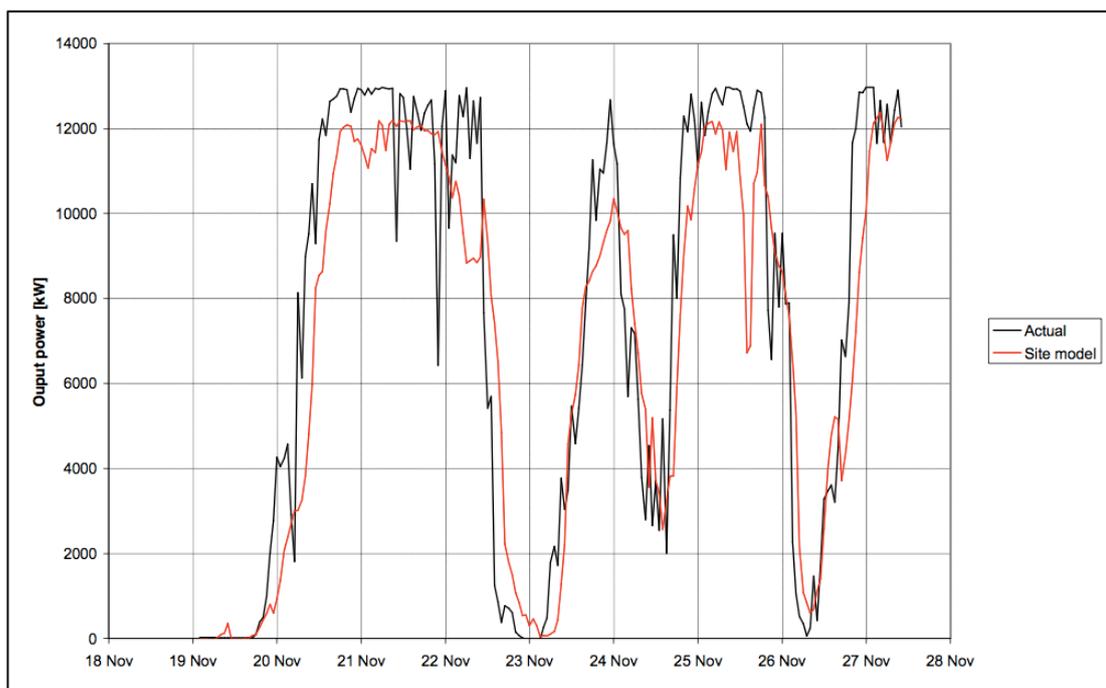


Figura 5.22: Ejemplo de serie temporal de una predicción de energía, T + 12 h.

Fuente: Garrad Hassan

Las predicciones meteorológicas mostradas anteriormente se convirtieron en energía utilizando una matriz de energía inferior a la óptima. En la figura 5.11 aparece la serie temporal resultante.

Desde el punto de vista del ingeniero, esta predicción parece buena. Resulta evidente que la predicción ha captado la evolución de la producción real bastante bien. El nivel máximo de producción se podría ciertamente mejorar, aunque esta es una cuestión de puesta a punto mas perfeccionada. Desde el punto de vista comercial, la situación, sin embargo, no parece tan buena. El hecho de que el intervalo de la predicción y de la energía real sea diferente es crucial. Por ejemplo, el 20 de noviembre, el incremento real en la energía, que es muy pronunciado, está retrasado respecto a la predicción, y aunque la figura es buena, el error absoluto en base horaria será muy grande. Para realizar ofertas en base horaria con dichas predicciones, los resultados serían muy malos. Que el pronóstico sea o no “bueno” o “malo”, depende en gran medida de la precisión que se necesite. Para programar el mantenimiento de planta es aceptable, mientras que para un fin comercial horario no sería útil. El objetivo de la predicción necesita ser definido muy cuidadosamente. Esta es una cuestión estratégica y técnica.

En general, G&H combina los datos de diversas predicciones meteorológicas, así como datos SCADA como datos de entrada de su modelo, como medio de optimizar la predicción meteorológica inicial. Obtenida la predicción de viento se combina con una curva de potencia del parque realizada a partir de históricos de entre uno y dos años.

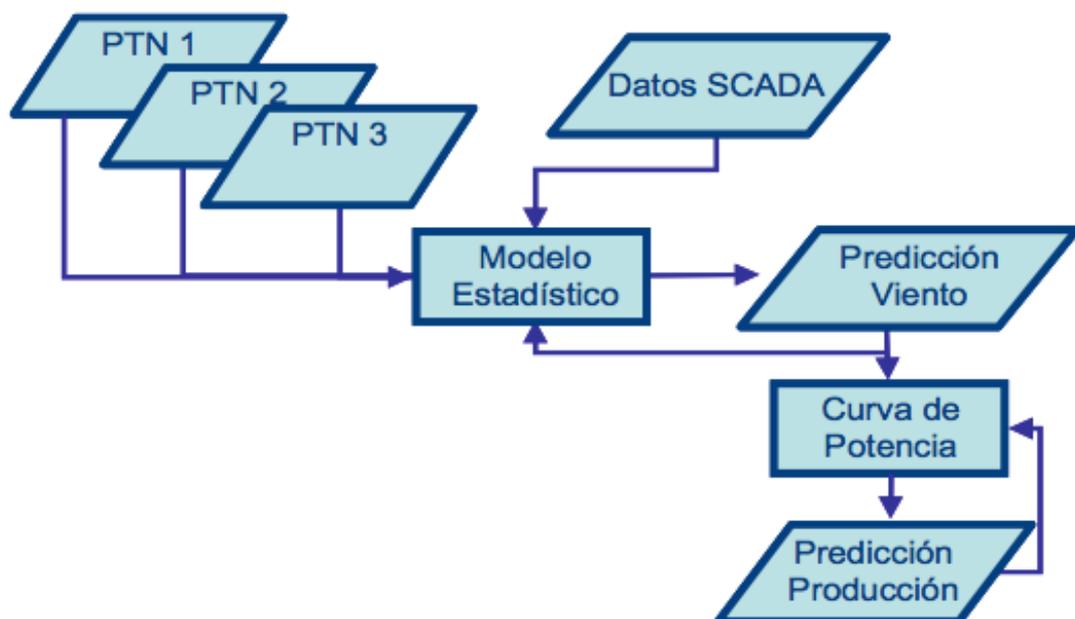


Figura 5.23: Características del modelo Garrad Hassan.

Fuente: Garrad Hassan

5.7.3 Meteosim

Meteosim S.L. se fundó en el año 2003 como fruto de la investigación de buena parte de sus integrantes en el campo de la modelización mesoescalar y de la predicción numérica del tiempo (PNT). Esta investigación comenzó en el año 1994 con la puesta operativa del primer modelo meteorológico mesoescalar desde un Departamento Universitario con la colaboración de Meso Inc [38].

Desde su creación, Meteosim ha dedicado sus recursos de Investigación y Desarrollo en la creación de productos derivados de la predicción numérica del tiempo en el sector energético con importantes aportaciones en el conjunto empresarial. Los esfuerzos en la predicción numérica les han convertido en referentes en la predicción precisa y fiable para empresas meteorológicamente sensibles.

En la actualidad Meteosim realiza más de 100 simulaciones meteorológicas diarias en los cinco continentes con diferentes configuraciones y resoluciones dependiendo de las necesidades del cliente.

Meteosim utiliza el modelo de predicción eWind, el cual utiliza un modelo meteorológico de mesoescala que ha sido adaptado para producir previsiones fiables del viento cerca de la superficie. Éste modelo emplea como datos de entrada las salidas del modelo global GFS, junto con observaciones de la red sinóptica. Las previsiones del modelo de mesoescala se introducen a continuación en un sistema de adaptación estadística, que ajusta constantemente las previsiones de viento y de producción eléctrica.

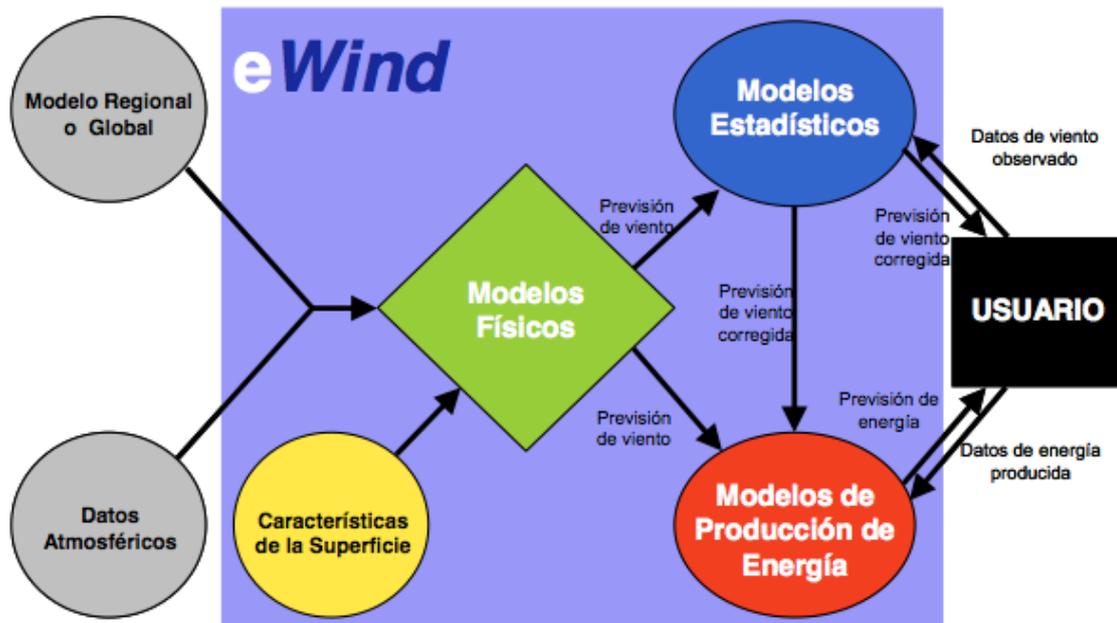


Figura 5.24: Características del modelo eWind.

Fuente: Meteosim

5.7.4 EA2

El sistema EA2 es producto de la tecnología propia desarrollada por el Instituto de Ingeniería del Conocimiento (IIC), basada en modelos estadísticos y, en particular, redes neuronales [38]. El objetivo inmediato del motor de predicción EA2 es ayudar a las empresas productoras de energía eléctrica de procedencia eólica a realizar ofertas precisas de energía al Operador del Mercado Eléctrico español (OMEL).

En un segundo plano y por extensión del objetivo inmediato, el motor EA2 -dados los niveles crecientes de potencia eólica instalada y la cada vez mayor importancia de los flujos eléctricos de procedencia eólica al sistema eléctrico- pretende servir de ayuda eficaz al operador de la red en la planificación de la oferta eléctrica a nivel nacional.

La emisión de predicciones de producción de energía eléctrica de origen eólico se realiza a partir de datos históricos de predicción meteorológica y de producción eléctrica, tanto para un parque eólico concreto como para un conjunto de ellos contenido en un área más amplia, como por ejemplo, la península ibérica.

Con la aportación de nuevos datos, tanto de predicción meteorológica como de producción de energía eléctrica EA2 genera nuevos modelos, con lo que de un modo muy dinámico, el sistema recoge esta nueva información y reinterpreta las condiciones del entorno generando de esta manera una nueva información altamente fiable: la predicción. EA2 genera un mínimo de dos modelos al día; el máximo dependerá de la frecuencia de refresco de los datos de entrada.

La arquitectura básica del sistema es la que se representa en la figura 5.25:

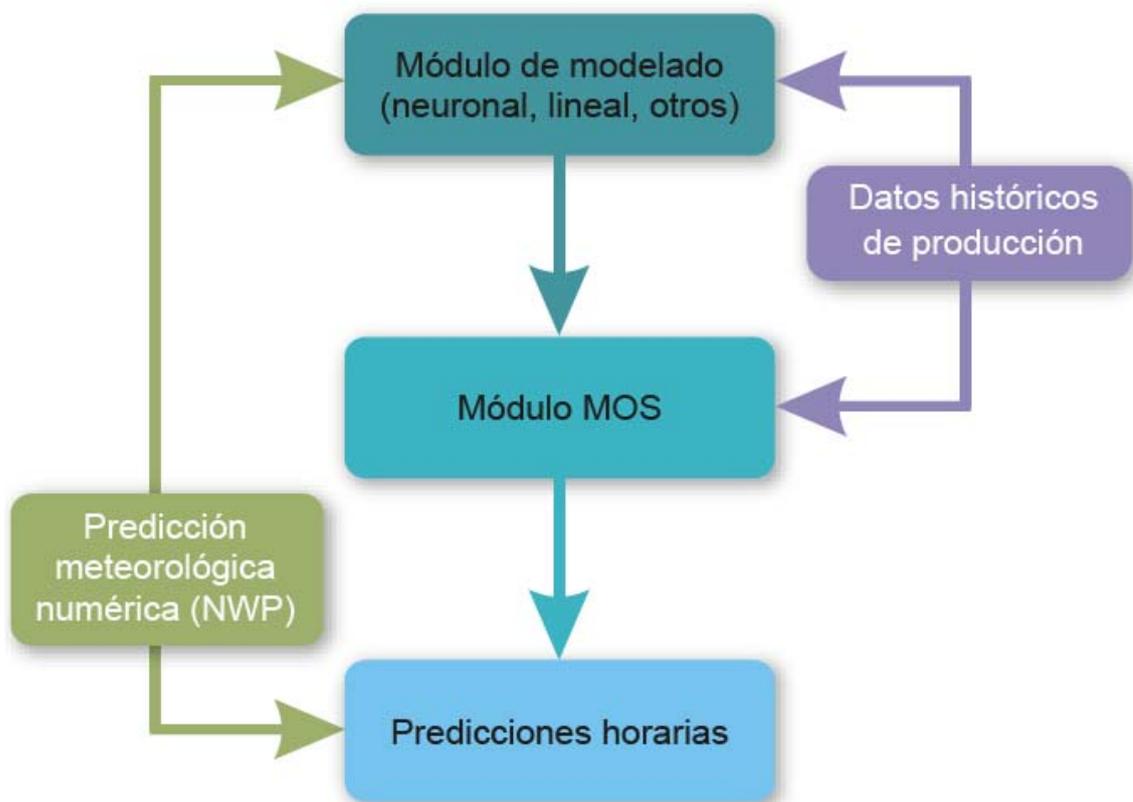


Figura 5.25: Arquitectura del sistema EA2

Fuente: IIC

Las predicciones así obtenidas se dan con un horizonte coincidente con el de la predicción meteorológica. El horizonte de predicción eficaz contrastada se corresponde con el que va de +12 h. a +48 h.

PRODUCTOS Y SERVICIOS

Las predicciones de EA2 pueden aplicarse tanto al mercado diario, como al intradiario, así como para, por ejemplo, la gestión de mantenimiento de parques. EA2 está disponible bajo un contrato de licencia o bien como solución software como servicio (SaaS), disponible 24 horas al día todos los días del año. En este segundo caso, el cliente recibe un determinado número de predicciones al día, típicamente una cada hora, bajo una comunicación mediante ftp o correo electrónico, en un servicio que garantiza en cada momento la protección de la información del cliente.

El modelo de funcionamiento de EA2 le permite ser aplicado prácticamente en cualquier área del globo.

5.8 EJERCICIO DE PREDICCIÓN

La Asociación Empresarial Eólica, promovió, dentro de sus actividades técnicas, un proyecto relacionado con la predicción de la producción de energía de parques eólicos, conocido como Ejercicio de Predicción [40]. El proyecto contó con la financiación de la AEE, de las empresas propietarias de los parques y subvención del programa PROFIT del Ministerio de Educación y Ciencia.

Sobre un conjunto de siete parques eólicos se realizó por diferentes empresas predictoras la predicción operativa diaria durante un periodo que abarcó desde Agosto de 2004 hasta finales de Marzo de 2006.

Gracias a este ejercicio se pudo llegar a varias conclusiones:

Los resultados de los diferentes modelos de predicción mostraron la importancia de la calidad de los datos meteorológicos de los modelos globales de entrada, que deben mejorar tanto por la reducción de la malla de definición como por el uso combinado de diferentes modelos de mesoescala.

Resultó, asimismo, importante reducir los plazos entre la recogida de los datos meteorológicos, su tratamiento y la salida de los Modelos Numéricos de los Centros Meteorológicos.

Para evitar discrepancia entre los resultados que presentan los modelizadores, para el cálculo de los errores se utilizaron únicamente dos parámetros:

EMAP: Error medio absoluto de producción para un periodo determinado. Puede interpretarse como el porcentaje que supone la suma de los valores absolutos de los errores respecto a la producción total.

EMAE: Error medio absoluto de estado, igual que el anterior pero dividido para la potencia nominal, y también para un periodo de un mes. Puede interpretarse como el valor medio del error absoluto del factor de capacidad predicho.

Para el escenario del Ejercicio, se demostró que los modelos estadísticos mostraron un grado de exactitud suficiente a un coste razonable. El EMAP promedio para todos los predictores se situó en el entorno del 45%.

El EMAP mensual mínimo alcanzable fue del orden del 25% y mejoras adicionales sólo pudieron obtenerse por la mejora los datos de entrada, el suministro de datos de los parques y el "ensemble" de modelos.

La influencia de la complejidad del terreno sobre la predicción es, o bien despreciable, o bien lo muy pequeña comparada con otros factores, por lo que no es determinante a la hora de evaluar las bondades de los modelos de predicción.

La agrupación de predicciones de parques disminuye los errores. La máxima disminución se consigue con la agrupación de los siete parques del Ejercicio, y supone alrededor de la mitad del error original del parque sin agrupar.

A lo largo del Ejercicio y los meses de la ampliación, los resultados obtenidos fueron:

- El EMAP promedio para todos los predictores se sitúa en el entorno del 45%.
- El EMAP mínimo alcanzado por un predictor es del orden del 20%.

5.9 REFERENCIAS:

- [1]: E. Kalnay, M. Kanamitsu, R. Kistler, W. Collins, D. Deaven, L. Gandin, M. Iredell, S. Saha, G. White, J. Woollen, y others, "The NCEP/NCAR 40-year reanalysis project," *Bulletin of the American Meteorological Society*, vol. 77, 1996, págs. 437–472.
- [2]: G. Grell, J. Dudhia, y D. Stauffer, A description of the fifth-generation Penn State/NCAR mesoscale model (MM5), Boulder, Colorado: National Center for Atmospheric Research, 1994.
- [3]: R.A. Pielke, W.R. Cotton, R.L. Walko, C.J. Tremback, W.A. Lyons, L.D. Grasso, M.E. Nicholls, M.D. Moran, D.A. Wesley, T.J. Lee, y others, "A comprehensive meteorological modeling system—RAMS," *Meteorology and Atmospheric Physics*, vol. 49, 1992, págs. 69–91.
- [4]: "WASP – the Wind Atlas Analysis and Application Program," <http://www.wasp.dk/>.
- [5]: M. Negnevitsky y C. Potter, "Innovative short-term wind generation prediction techniques," 2006 IEEE Power Engineering Society General Meeting, Montreal, Que., Canada: 2006, pág. 7 pp.
- [6]: G. Kariniotakis, I. Marti, D. Casas, P. Pinson, T. Nielsen, H. Madsen, G. Giebel, J. Usaola, I. Sanchez, A. Palomares, R. Brownsword, J. Tambke, U. Focken, M. Lange, P. Louka, G. Kallos, C. Lac, G. Sideratos, y G. Descombes, "What performance can be expected by short-term wind power prediction models depending on site characteristics ?," 2004 European Union Wind Energy Conference an Exhibition, London: 2004.
- [7]: A. Joensen, G. Giebel, L. Landberg, H. Madsen, y H. Nielsen, "Model output statistics applied to wind power prediction," *Proceedings of the European Wind Energy Conference, EWEC'99*, Nice, France: 1999, págs. 1177-1180.
- [8]: L. Landberg y S.J. Watson, "Short-term prediction of local wind conditions," *Boundary-Layer Meteorology*, vol. 70, Jul. 1994, págs. 171-195.
- [9]: G. Giebel, L. Landberg, T.S. Nielsen, y H. Madsen, "Zephyr - The Next Generation Prediction System," *Proceedings of the 2002 Global Windpower Conference*, Paris, France: 2002.

- [10]: U. Focken, M. Lange, y H.P. Waldl, "Previento-a wind power prediction system with an innovative upscaling algorithm," Proceedings of the European Wind Energy Conference, Copenhagen, Denmark, 2001, págs. 2–6.
- [11]: H. Beyer, H. Heinemann, K. Mellinshoff, K. Mönnich, y H. Waldl, "Forecast of Regional Power Output of Wind Turbines," Proceedings of the European Wind Energy Conference, Nice, France: 1999, págs. 1070-1073.
- [12]: B. Bailey, M. Brower, y J. Zack, "Short-term wind forecasting: development and application of a mesoscale model," Proceedings of the European Wind Energy Conference, EWEC'99, Nice, France: 1999, págs. 1062-1095.
- [13]: J.W. Zack, M.C. Brower, y B.H. Bailey, "Validating of the Forewind model in wind forecasting applications," Talk on the EUWEC Special Topic Conference Wind Power for the 21st Century, Kassel, Germany: 2000.
- [14]: I. Marti, T.S. Nielsen, H. Madsen, J. Navarro, A. Roldan, D. Cabezón, y C. Barquero, "Prediction Models in Complex Terrain," Proceedings of the European Wind Energy Conference, Copenhagen, Denmark: 2001, págs. 875- 878.
- [15]: I. Marti, D. Cabezón, J. Villanueva, M. Sanisidro, Y. Loureiro, E. Cantero, y J. Sanz, "LocalPred and RegioPred. Advanced tools for wind energy prediction in complex terrain."
- [16]: J. Jorgensen, C. Moehrlen, B. O Gallaghóir, K. Sattler, y E. McKeogh, "HIRPOM: Description of an operational numerical wind power prediction model for large scale integration of on- and offshore wind power in Denmark," Poster on the Global Windpower Conference and Exhibition, Paris, France: 2002.
- [17]: Estudio sobre Predicción eólica en la Unión Europea. ANEMOS. Promovido por el IDAE. Madrid, mayo de 2007.
- [18]: R.E. Kalman, "A new approach to linear filtering and predictions problems", Transactions of the ASME–Journal of Basic Engineering, Vol. 82, 35-45, 1960.
- [19] G. González, B. Díaz-Guerra, F. Soto, S. Lopez, I. Sánchez, J. Usaola, M. Alonso, y M. Lobo, "SIPREOLICO: Wind power prediction tool for the Spanish peninsular power system," 2004 CIGRÉ 40th General Session & Exhibition, Paris, France: 2004.
- [20] G. González, A. Lopez, E. Prieto, I. Sánchez, y M. Lobo, "SIPREOLICO: Wind Power Prediction Tool. Improvements in the Period 2005-2007," CIGRE, 2008.
- [21] I. Sánchez, "Recursive Estimation of Dynamic Models Using Cook's Distance, With Application to Wind Energy Forecast," Technometrics, vol. 48, 2006, págs. 61-73.

- [22] I. Sánchez, "Short-term prediction of wind energy production," *International Journal of Forecasting*, vol. 22, 2006, págs. 43-56.
- [23] I. Sánchez, "Adaptive combination of forecasts with application to wind energy," *International Journal of Forecasting*, vol. 24, Oct. , págs. 679-693.
- [24] "ANEMOS Project. Short-Term Wind Power Forecasting," <http://anemos.cma.fr>.
- [25] "ANEMOS: Development of a Next Generation Wind Power Forecasting System for the Large-Scale Integration of Onshore & Offshore Wind Farms.," *European Wind Energy Conference & Exhibition EWEC 2003, Madrid, Spain: 2003*.
- [26] H. Madsen, G. Kariniotakis, H.A. Nielsen, y P. Pinson, "A protocol for standardizing the performance evaluation of short-term wind power prediction models," *Proceedings of the 2004 Global Windpower Conference and Exhibition, Chicago, Illinois, USA: 2004*.
- [27] T. Nielsen, H. Madsen, H. Nielsen, P. Pinson, G. Kariniotakis, y N. Siebert, "Short-term wind power forecasting using advanced statistical methods," *Proceedings of European wind energy conference, Athens, Greece: 2006*.
- [28] G. Giebel, J. Badger, I. Marti, P. Louka, G. Kallos, y A. Palomares, "Shortterm forecasting using advanced physical modeling—the results of the ANEMOS project," *Proceedings of European wind energy conference, Athens, Greece: 2006*.
- [29] J. Tambke, L. von Bremen, R. Barthelmie, A. Palomares, T. Ranchin, y J. Juban, "Short-term forecasting of offshore wind farm production— developments of the ANEMOS project," *Proceedings of European wind energy conference, Athens, Greece: 2006*.
- [30] G. Kariniotakis, I. Marti, D. Casas, P. Pinson, T. Nielsen, H. Madsen, G. Giebel, J. Usaola, I. Sanchez, A. Palomares, R. Brownsword, J. Tambke, U. Focken, M. Lange, P. Louka, G. Kallos, C. Lac, G. Sideratos, y G. Descombes, "What performance can be expected by short-term wind power prediction models depending on site characteristics ?," *2004 European Union Wind Energy Conference an Exhibition, London: 2004*.
- [31]: Ejercicio de predicción. AEE. Proyecto cofinanciado con el programa PROFIT y con la participación del Instituto Nacional de Meteorología. Diciembre 2006.
- [32]: AEOLIS. Servicio Meteorológico. <http://www.aeolis.nl/site/english/home/1>. 2014.
- [33]: Casandraenergy. Parques Eólicos. <http://www.casandraenergy.com/sp/home.htm>. 2013.

- [34]: CENER. Energías Renovables. <http://www.cener.com/es/index.asp>. 2014.
- [35]: Meteologica. Energías Renovables.
<http://www.meteologica.com/meteologica/>. 2015.
- [36]: Aleasoft. Previsiones. <http://www.aleasoft.com/>. 2014.
- [37]: Garrad Hassan. Energía. <http://www.gl-garradhassan.com/en/index.php>.
2014.
- [38]: Meteosin. Modelización. <http://www.meteosim.com/modeling>. 2014.
- [39]: MUÑOZ, A. Aplicación de técnicas de redes neuronales al diagnóstico de procesos industriales. Tesis Doctoral. E.T.S.I. ICAI. Universidad Pontificia Comillas de Madrid.
- [40]: Ejercicio de predicción. AEE. Proyecto cofinanciado con el programa PROFIT y con la participación del Instituto Nacional de Meteorología. Diciembre 2006.

CAPITULO 6

Las Redes Neuronales

INDICE

6 Las Redes Neuronales.....	165
6.1 Introducción a las Redes Neuronales.....	165
6.2 Desarrollo histórico de las redes neuronales.....	169
6.3 Funcionamiento de una neurona biológica.....	171
6.4 Características de una red neuronal artificial.....	177
6.4.1 Notación.....	180
6.4.2 Funciones de transferencia.....	181
6.4.3 Tipología de una red.....	183
6.4.4 Aprendizaje de las Redes Neuronales.....	189
6.5 Principales tipos de Redes Neuronales.....	192
6.5.1 Perceptron.....	192
6.5.1.1 Antecedentes.....	192
6.5.1.2 Estructura de la red.....	196
6.5.2 Adaline.....	198
6.5.2.1 Antecedentes.....	198
6.5.2.2 Estructura de la red.....	199
6.5.3 Backpropagation.....	201
6.5.3.1 Antecedentes.....	201
6.5.3.2 Estructura de la red.....	204
6.5.3.3 Regla de aprendizaje.....	205
6.6 Referencias.....	218

INDICE DE FIGURAS

Figura 6.1: Neurona Biológica

Figura 6.2: Neurona Real

Figura 6.3: Cambios asociativos de las fuerzas sinápticas durante el aprendizaje

Figura 6.5: Proceso de una sinapsis

Figura 6.4: Comunicación entre neuronas

Figura 6.5: Proceso de una sinapsis Comunicación entre neuronas

Figura 6.6: Neurona Artificial

Figura 6.7: De la neurona biológica a la neurona artificial

Figura 6.8: Proceso de una red neuronal

Figura 6.9: Neurona de una sola entrada

Figura 6.10: Funciones (a) escalón, (b) rampa, (c y d) funciones sigmoides

Figura 6.11: Neurona con múltiples entradas

Figura 6.12: Neurona con múltiples entradas, notación abreviada

Figura 6.13: Capa de S neuronas

Figura 6.14: Red de tres capas

Figura 6.15: Red de tres capas con notación abreviada

Figura 6.16: Redes Recurrentes

Figura 6.17: Bloque de retardo

Figura 6.18: Bloque integrador

Figura 6.19: Aprendizaje supervisado

Figura 6.20: Aprendizaje no supervisado

Figura 6.21: Secuencia del desarrollo de una aplicación basada en red neuronal artificial

Figura 6.22: Modelo del Fotoperceptrón de Rosenblatt

Figura 6.23: Esquema de conexiones de un Perceptrón sencillo

Figura 6.24: Perceptrón según Minsky y Papera

Figura 6.25: Perceptrón

Figura 6.26: Capacidad de decisión de las redes neuronales artificiales (perceptrón multicapa)

Figura 6.27: Estructura de una red Adaline

Figura 6.28: Adaline de una neurona y dos entradas

Figura 6.29: Características de decisión de una red tipo Adaline

Figura 6.30: Red de tres capas

Figura 6.31: Notación compacta de una red de tres capas

Figura 6.32: Disposición de una red sencilla de 3 capas

Figura 6.33: Superficie típica de error

Figura 6.34: Intervalo de la función t

Figura 6.35: Red utilizada para aproximar la función

INDICE DE TABLAS

Tabla 6.1: Resumen de los aspectos más relevantes en el entorno de la neurona artificial.

Tabla 6.2: Clasificación de las Redes Neuronales según tipo de aprendizaje y arquitectura

6 LAS REDES NEURONALES

6.1 Introducción a las redes neuronales

El desarrollo de máquinas que puedan imitar la capacidad de aprendizaje del hombre es actualmente un desafío en el que pone sus miras buena parte de la comunidad científica.

Llevado a una visión humana tenemos el cerebro, que está compuesto de millones de neuronas, las cuales tienen como funcionamiento principal interrelacionarse y auto alimentarse de información entrante, para así luego crear un estado de procesamiento lo que permite generar una salida de información.

En base a las redes biológicas del cerebro nace la idea de crear un sistema autónomo capaz de intercambiar información, reconocer patrones, manuscritos, secuencia de tiempo, tendencias y junto con ello la capacidad de aprender y mejorar su funcionamiento emulando así el ya mencionado sistema cerebral, cuyos componentes principales son las células más pequeñas del cerebro llamadas "Neuronas".

Una Red Neuronal es el resultado de los intentos por reproducir mediante computadoras el funcionamiento del cerebro humano. El cerebro está compuesto por miles de millones de neuronas, interconectadas de forma variable y compleja. Su peculiar forma de trabajo le convierte en el dispositivo más eficaz para procesar información del mundo real.

Cada neurona recibe impulsos procedentes de otras neuronas, que procesa individualmente dándole un peso determinado. Después transmite la señal resultante a otras neuronas, siguiendo una configuración variable para cada caso. Las redes neuronales tratan de simular este proceso en un equipo computacional [20].

El papel de las neuronas es tomado por los nodos, que son pequeñas unidades inteligentes con capacidad de almacenar y procesar señales.

Al igual que las neuronas en el cerebro humano, cada nodo recibe unas señales que proceden del exterior de la red o de otros nodos, las procesa dando distinto peso a cada una y genera una única señal de salida que se transmite a otros nodos.

Desde el punto de vista práctico, un nodo debe poseer los medios para almacenar señales y procesarlas según pesos o funciones. Por lo mismo, los nodos deben ser circuitos electrónicos, computadoras o fragmentos de programas.

Para simplificar el diseño de las redes, los especialistas realizan topologías sencillas de distribución de nodos, disponiéndolos en capas sucesivas. Una de las más utilizadas, sitúa los nodos en tres niveles (entrada, intermedio, salida) en los que cada nodo actúa con las señales de la misma forma. La topología es sencilla de llevar a la práctica (mediante un programa) y produce redes neuronales que aprenden por sí mismas [18].

En los inicios de la revolución tecnológica, cuando se querían obtener diferentes señales de salida de un sistema, dependiendo de los tipos y niveles de estímulo presentes en su entrada, era necesario dotarle de una relación matemática entre dichas entradas y salidas.

Con la aparición de las redes neuronales, el sistema se autorregula, deduciendo los pesos que debe de dar a las distintas señales y la forma de conectar los nodos. Tras esta regulación, puede trabajar en situaciones para las que aún no se hayan establecido reglas de funcionamiento.

Una red neuronal nueva establece las conexiones de cada nodo de forma convencional. Su proceso de aprendizaje empieza al darle una pareja de datos de entrada y salida. La red va haciendo pruebas mediante la determinación de los pasos más convenientes y de las conexiones entre nodos más adecuadas. Al cabo de varios intentos, repetidos con varias parejas de datos de entrada y salida conocidos, el sistema está ya educado, es decir, en condiciones de trabajar; la información que almacena una red se halla dispersa por todos sus nodos, lo que le confiere características distintas a las de una computadora convencional y le hace menos propensa a fallos.

Es fácil suponer que una de las primeras aplicaciones es la simulación del cerebro humano y sus cientos de miles de millones de neuronas. Hasta la fecha sólo se ha logrado simular unas 10.000, lo que no está mal, pero quedó lejos del órgano original. En esas simulaciones se han empleado grandes computadoras, que han necesitado horas para repetir procesos que el cerebro realiza en segundos. Se sigue intentando desarrollar un

modelo donde experimentar los efectos de nuevas medicinas, el comportamiento ante estímulos, etc.

Las redes neuronales artificiales son sistemas paralelos para el procesamiento de la información, éstas tratan de resolver en forma eficiente problemas y a su vez representar el conocimiento de un modo conexionista y adaptativo. Se denomina también neurocomputación y se compone de capas agrupadas en donde varias redes más los interfaces del entorno conforman el sistema global denominado red neuronal que está confeccionado y entrenado para llevar a cabo una labor específica.

La 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 [2-7] 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 [21]. 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.

Aunque existen diferentes modelos de conexiones entre capas, se pueden distinguir dos que son las más relevantes:

- Feedforward o Arquitecturas hacia adelante en que la información siempre es progresiva.
- Feedback o realimentadas en donde la información fluye hacia atrás como lazos de realimentación.

6.2 Desarrollo histórico de las redes neuronales

Partiendo de que las redes neuronales se fundamentan en el sistema nervioso humano deberíamos remontarnos a los tiempos de Galeno en los que ya se tenía un conocimiento considerable de éste. Sin embargo, los verdaderos avances en neurología se produjeron a partir de la segunda mitad del siglo XIX. Investigadores ilustres de esta época son Jackson, Ramón y Cajal y Golgi entre otros.

Fue en 1943 cuando Warren McCulloch y Walter Pitts propusieron el clásico modelo de neurona en el que se basan las redes neuronales actuales. Seis años después, en 1949, en su libro *The Organization of Behavior*, Donald Hebb presentaba su conocida regla de aprendizaje.

En 1957, Frank Rosenblatt presentó el Perceptrón, una red neuronal con aprendizaje supervisado cuya regla de aprendizaje era una modificación de la propuesta por Hebb. El Perceptrón trabaja con patrones de entrada binarios, y su funcionamiento, por tratarse de una red supervisada, se realiza en dos fases: una primera en la que se presentan las entradas y la salidas deseadas; en esta fase la red aprende la salida que debe dar para cada entrada. La principal aportación del Perceptrón es que la adaptación de los pesos se realiza teniendo en cuenta el error entre la salida que da la red y la salida que se desea. En la fase siguiente, de operación, la red «es capaz» de responder adecuadamente cuando se le vuelven a presentar los patrones de entrada. Se crearon grandes expectativas sobre sus aplicaciones, que posteriormente se tornaron en gran decepción cuando en 1969 Minsky y Papert demostraron las grandes limitaciones de esta red.

En los años 60 se propusieron otros dos modelos, también supervisados, basados en el Perceptrón de Rosenblatt denominados Adaline y Madaline. En estos, la adaptación de los

pesos se realiza teniendo en cuenta el error, calculado como la diferencia entre la salida deseada y la dada por la red, al igual que en el Perceptrón. Sin embargo, la regla de aprendizaje empleada es distinta. Se define una función error para cada neurona que da cuenta del error cometido para cada valor posible de los pesos cuando se presenta una entrada a la neurona. Así, la regla de aprendizaje hace que la variación de los pesos se produzca en la dirección y sentido contrario del vector gradiente del error. A esta regla de aprendizaje se la denomina Delta.

La era moderna de las redes neuronales artificiales surge con la técnica de aprendizaje de propagación hacia atrás o Back Propagation. La estructura de las redes citadas anteriormente (Perceptrón, Adaline y Madaline) consta de dos capas: una capa primera formada por unidades que dejan pasar la entrada y que no tienen aprendizaje, y una segunda capa formada por una o varias neuronas en el caso del Madaline. La contribución de Minsky y Papert fue la de demostrar que una red del tipo Perceptrón no es capaz de aprender todas las posibles combinaciones entre entradas y salidas. La solución del problema consiste en añadir capas intermedias de neuronas, introduciendo de esta forma el problema de cómo enseñar a estas capas intermedias. Aquí es donde tiene importancia el algoritmo de propagación hacia atrás. En éste se compara la salida real con la salida deseada. La diferencia entre ambas constituye un error que se propaga hacia atrás desde la capa de salida hasta la de entrada permitiendo así la adaptación de los pesos de las neuronas intermedias mediante una regla de aprendizaje Delta. Sin embargo, también tiene sus limitaciones.

Posteriormente se han desarrollado otros modelos que permiten un aprendizaje no supervisado como el mapa auto-organizativo de Kohonen, los basados en la Teoría de Resonancia Adaptativa (ART) de Grossberg y Carpenter, o los modelos de control motor de Bullock, Gaudiano y Grossberg, entre otros.

A modo de resumen, la siguiente tabla recoge los sucesos más destacados [11]:

Tabla 6.1: Resumen de los aspectos más relevantes en el entorno de la neurona artificial

1943	McCulloch y Pitts presentan la neurona formal.
1949	D. Hebb publica su regla de aprendizaje para neuronas.
1951	Minsky plantea su máquina neuronal.
1956	Rochester, Holland, entre otros, realizan pruebas sobre ensambles de células y su acción en el cerebro.
1958	Von Neumann propone un modelo para el cerebro.

1958	Rosenblatt propone el perceptrón.
1960	Widrow y Hopf presentan el Adaline y el aprendizaje por ajuste de mínimos cuadrados. Lo aplican a la eliminación del eco en llamadas telefónicas y constituye la primera aplicación práctica de las redes neuronales.
1969	Minsky y Papert analizan el preceptrón y encuentran que tiene limitaciones lógicas importantes.
1972	Kohonen presenta sus primeros trabajos sobre redes neuronales y memorias asociativas.
1972	J. Anderson desarrolla la red neuronal llamada: "estado cerebral en una caja".
1975	Fukushima, en los laboratorios NHK, en Tokio, desarrolla el cognitrón, una red neuronal especializada en reconocimiento de patrones. No logra reconocer caracteres distorsionados o rotados.
1976	Grossberg, en la Universidad de Boston, inicia sus trabajos sobre redes neuronales artificiales. Se distingue por su carácter altamente matemático y con sentido biológico.
1982	Kohonen presenta la red que ahora se llama mapeo autoorganizado (SOM por su nombre en inglés).
1982-1985	J. Hopfield presenta la red de aprendizaje mediante la regla de Hebb. Utiliza técnicas de la Física Estadística para demostrar que tiene propiedades de memoria asociativa. Gran impacto en el mundo de los físicos.
1984	Ackley, Hinton y Sejnoski desarrollan la máquina de Boltzmann. Una red neuronal
1985	Se establece el sistema de propagación hacia atrás, que había aparecido para ser olvidado en diversas ocasiones.
1986	Surge el mapeo de Kohonen.
2000	El paralelismo, las redes neuronales y la inteligencia artificial en general, convergen en una teoría del aprendizaje de desarrollo acelerado con aplicaciones muy diversas.

6.3 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 6.1

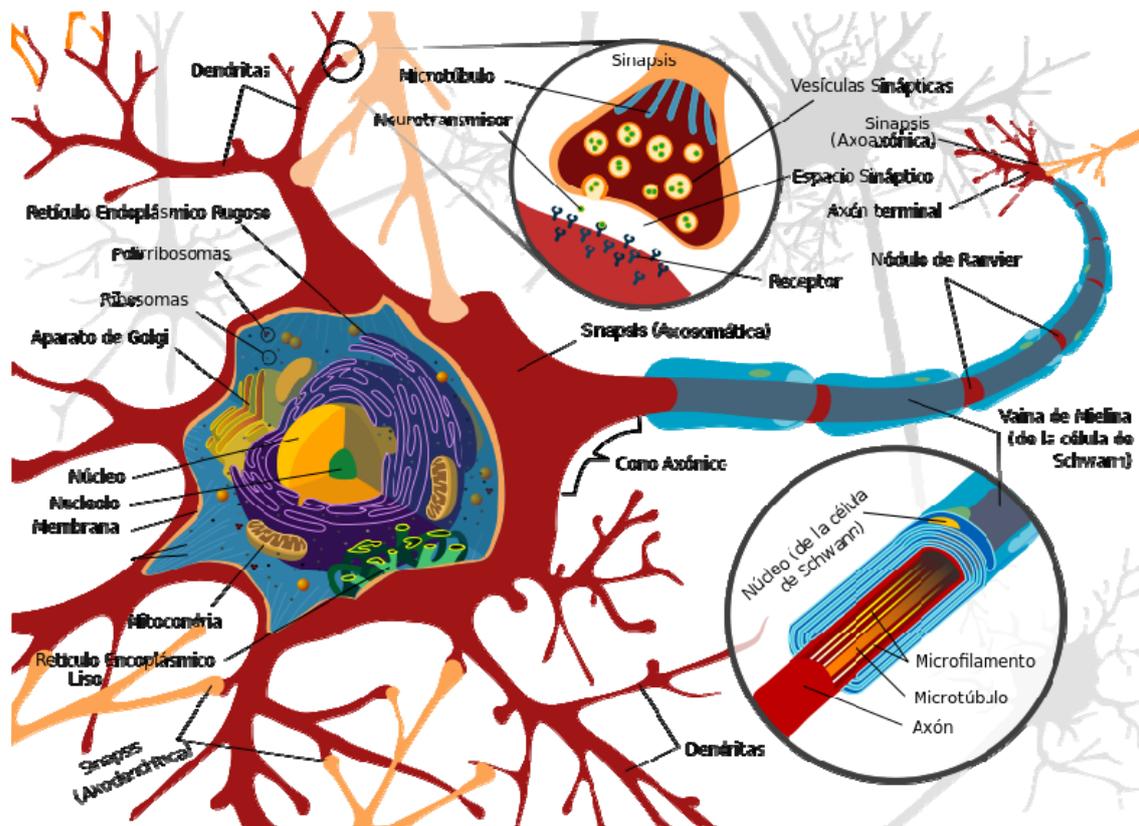


Figura 6.1: Neurona Biológica

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.

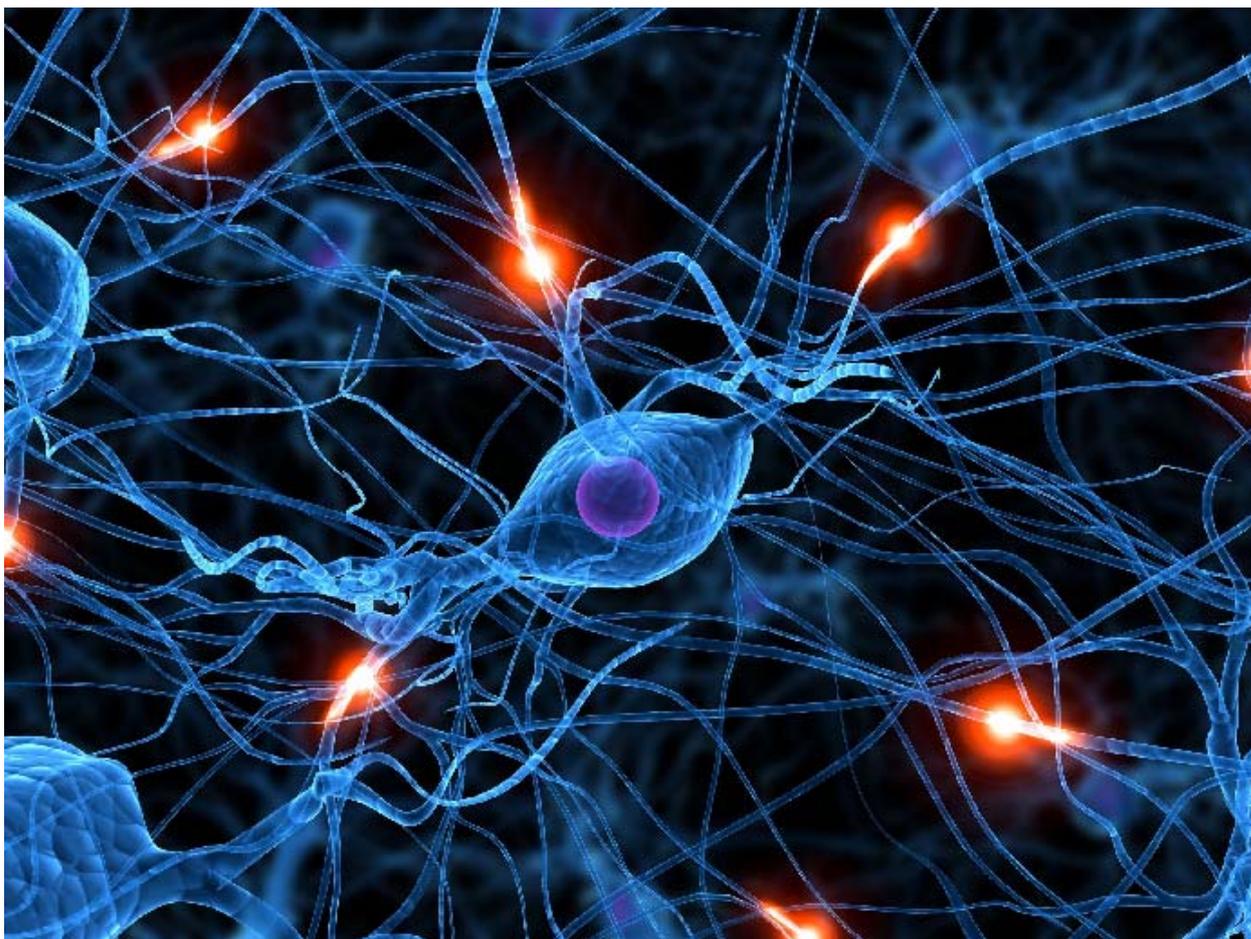


Figura 6.2: Neurona Real

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 6.3

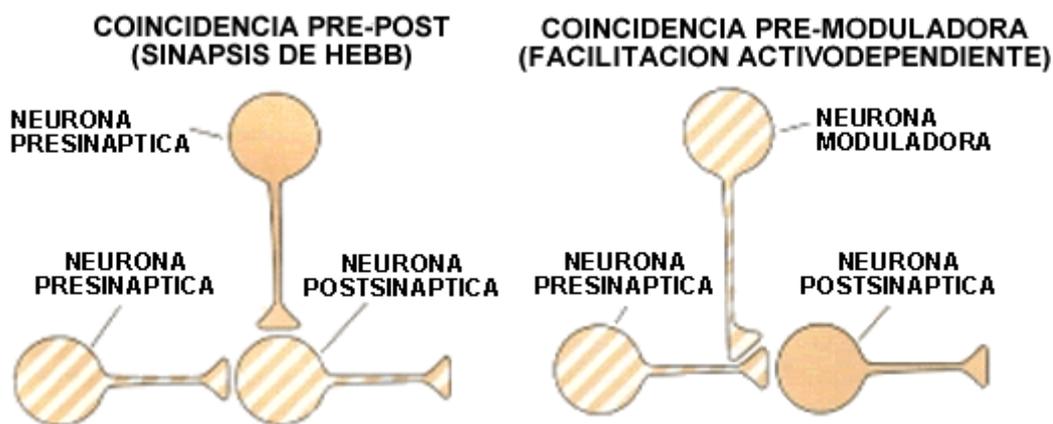


Figura 6.3: Cambios asociativos de las fuerzas sinápticas durante el aprendizaje

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 [22].

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 6.4.

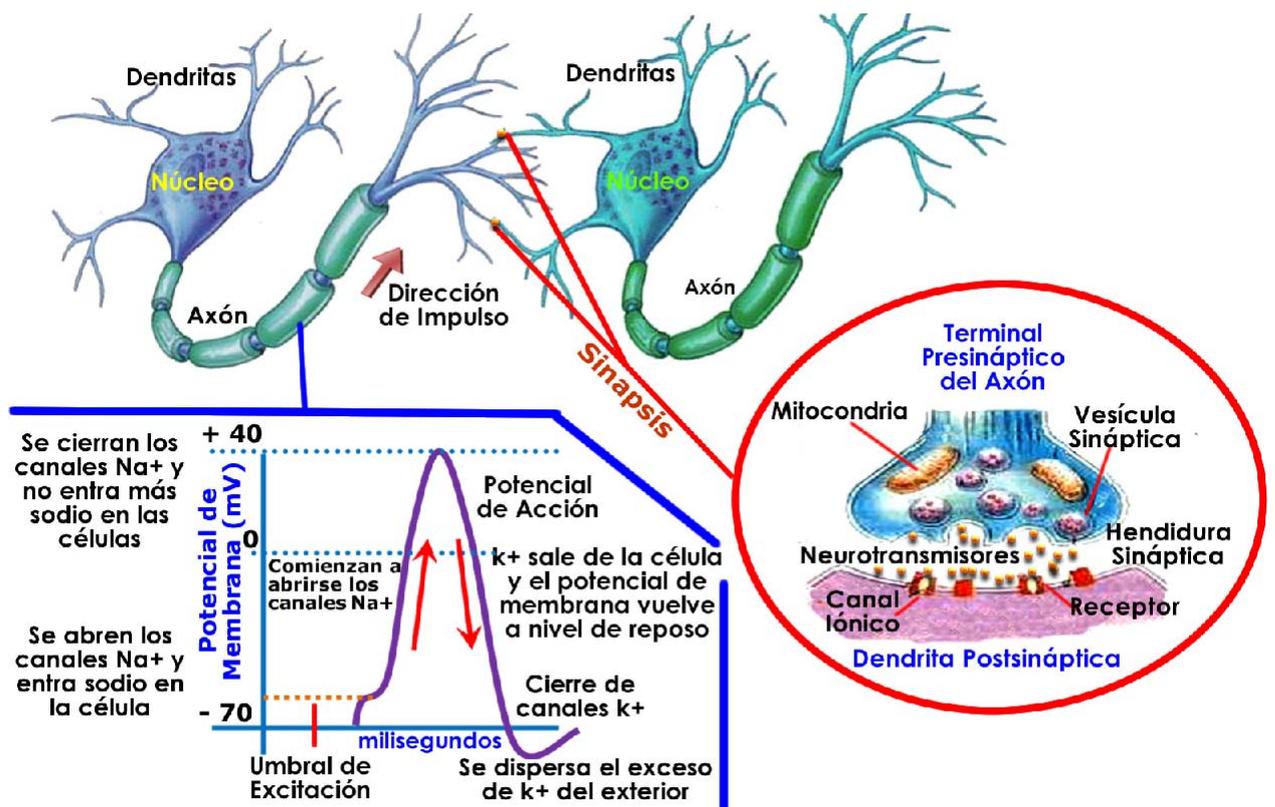


Figura 6.4: Comunicación entre neuronas

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 inhibitor. 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 6.5 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.

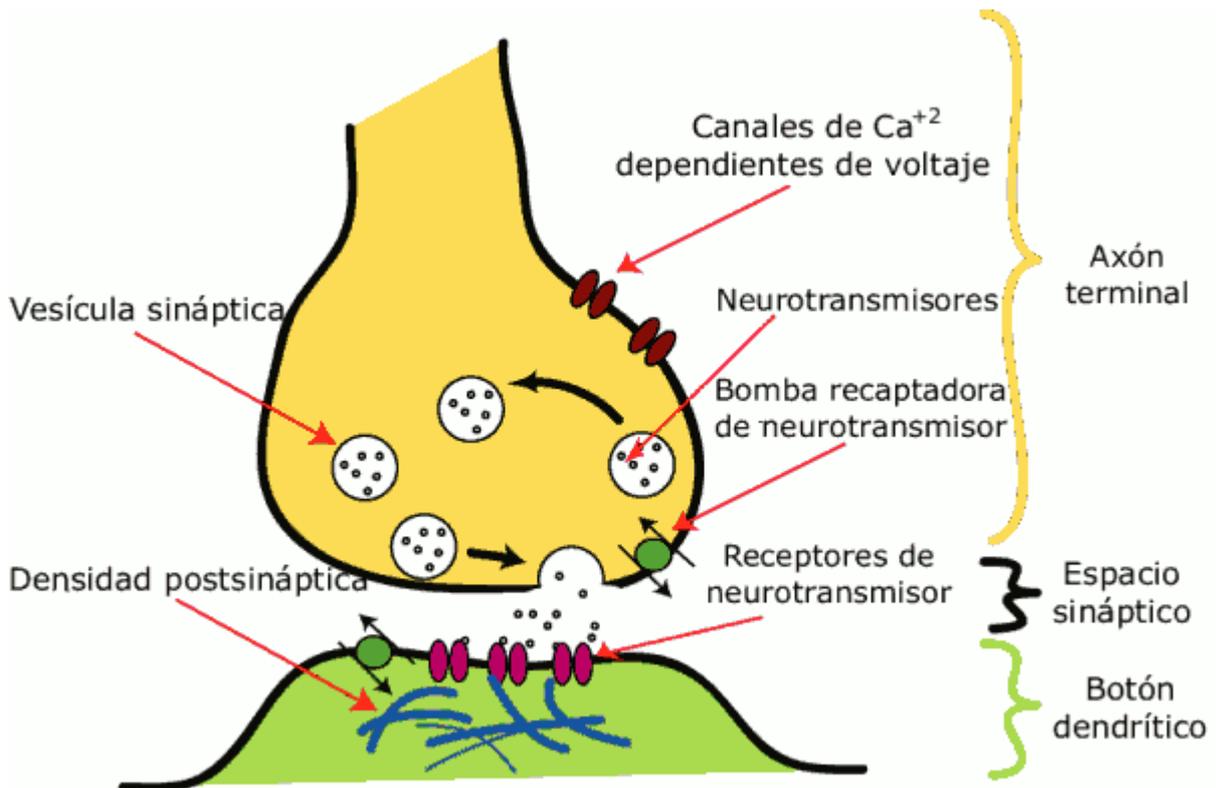


Figura 6.5: Proceso de una sinápsis

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.

6.4 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 6.6

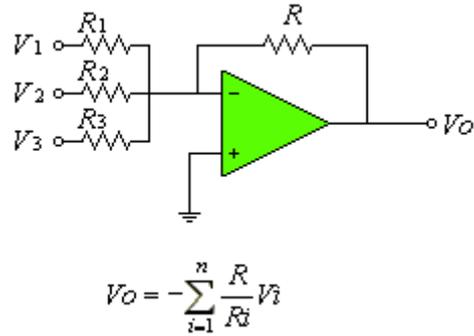


Figura 6.6: Neurona Artificial

Existen varias formas de nombrar una neurona artificial, es conocida como nodo, neuronodo, celda, unidad o elemento de procesamiento (PE); En la figura 6.7 se observa un PE en forma general y su similitud con una neurona biológica

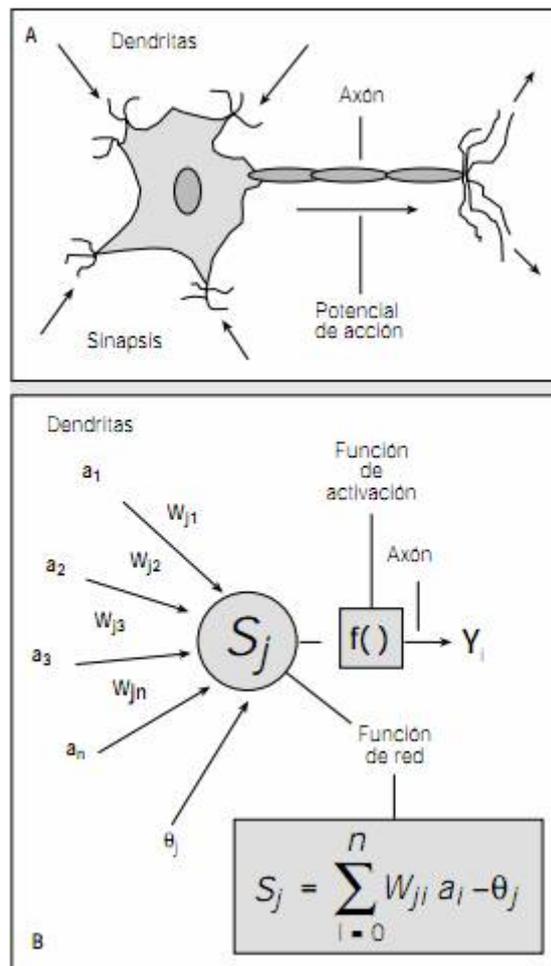


Figura 6.7: De la neurona biológica a la neurona artificial

De la observación detallada del proceso biológico se han hallado los siguientes análogos con el sistema artificial [15]:

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

Las señales de entrada a una neurona artificial A_i 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

$$\text{Ecuación 6.1} \quad \text{net}_i = \sum_{i=1}^n A_i X_i = \vec{A} \vec{W}$$

Una idea clara de este proceso se muestra en la figura 6.8, en donde puede observarse el recorrido de un conjunto de señales que entran a la red.

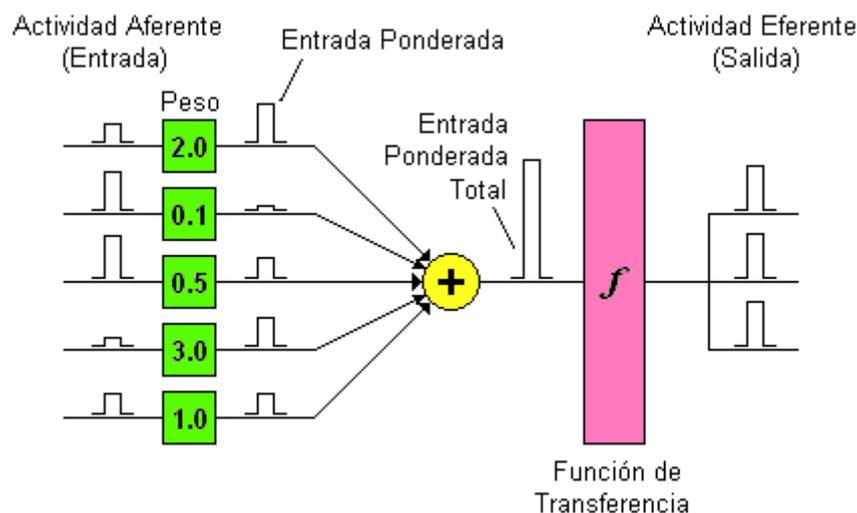


Figura 6.8: Proceso de una red neuronal

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

$$\text{Ecuación 6.2} \quad x_i = f_i(\text{net}_i)$$

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

6.4.1 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:

$$W_{s^c, s^c}^c$$

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

Así $W_{1,1}^2$ 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_{s^2, s^1}^2

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

6.4.2 Funciones de Transferencia:

Un modelo más académico que facilita el estudio de una neurona, puede visualizarse en la figura 6.9

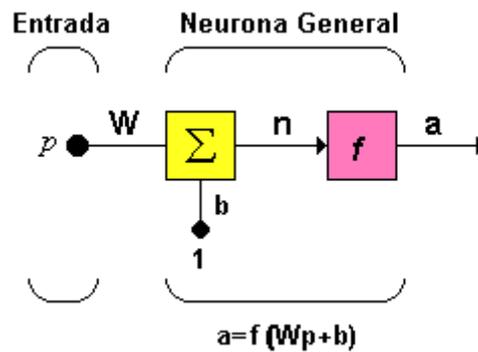


Figura 6.9: Neurona de una sola entrada

Las funciones de transferencia pueden tener muchas formas y métodos, siendo estas simples o complejas [14]. A la función de transferencia también se le conoce como umbral (*threshold*). Estas funciones definen y envían fuera de las neuronas los valores calculados. Existen diferentes tipos de funciones, las más utilizadas en la transferencia de las neuronas de la capa oculta y salida se visualizan en la Figura 6.10.

Para la activación o la inactivación de la salida de la red, se tiene que determinar las funciones de activación de las neuronas de la capa oculta y de la capa de salida, y definir los algoritmos de entrenamiento con propagación hacia atrás.

Las redes neuronales de varias capas presentan una serie de restricciones que se deben tener en cuenta a la hora de determinar la estructura óptima de la red. Entre otros aspectos, se encuentra la imposibilidad de conexión con capas anteriores y de conexión entre neuronas de una misma capa, como la existencia de una sola capa de entrada y otra de salida.

Otro problema que se plantea es la selección del número de capas ocultas de la red y del número de neuronas por capa. En este sentido, un número excesivo de capas puede generar ruido, pero se consigue una mayor tolerancia a fallas.

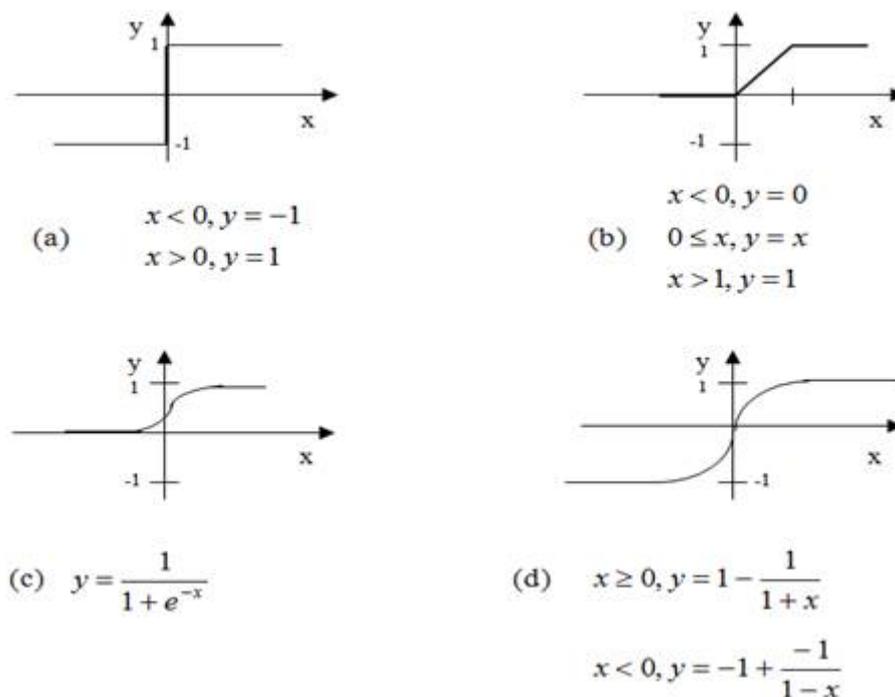


Figura 6.10: Funciones (a) escalón, (b) rampa, (c y d) funciones sigmoideas

En cuanto al número de neuronas por capa, cabe indicar que no existen reglas para su determinación [16]. El número de neuronas ocultas interviene en la eficacia del aprendizaje y generalización de la red. Si se consideran pocas neuronas ocultas puede suceder que la red no distinga bien las características del problema, provocando que en la fase de entrenamiento no se alcancen los límites especificados. Sin embargo, la definición de demasiadas neuronas ocultas, aunque no conduzcan a resultados erróneos, genera procesos tediosos de entrenamiento, además de producir la pérdida de capacidad de generalización de la red, debido a problemas de sobreparametrización. El siguiente aspecto es la división de la muestra al azar en dos grupos:

- El primero de ellos toma como patrón ejemplo para entrenar la red.
- El segundo se utiliza para comprobar la eficiencia de la misma.

La selección correcta de la muestra constituye uno de los principales factores que determinan el grado de eficiencia de la red. Con este fin, se procede a seleccionar

aleatoriamente o en forma secuencial el conjunto de variables que determinan el conjunto de patrones de aprendizaje, utilizando los restantes para la validación de la red. Este proceso se repite utilizando diversas submuestras de entrenamiento.

6.4.3 Topología de una Red:

Típicamente una neurona tiene más de una entrada; en la figura 6.11 se observa una neurona con R entradas; las entradas individuales p_1, p_2, \dots, p_R son multiplicadas por los pesos correspondientes $w_{1,1}, w_{1,2}, \dots, w_{1,R}$ pertenecientes a la matriz de pesos W .

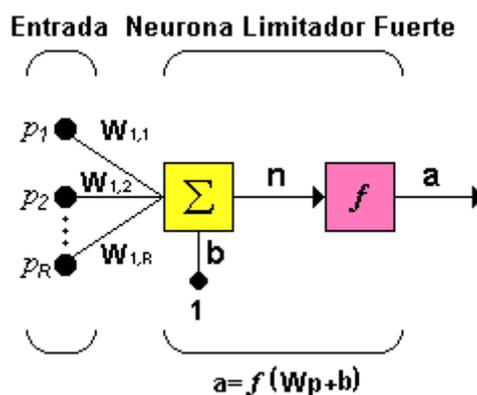


Figura 6.11: Neurona con múltiples entradas

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 ,

$$\text{Ecuación 6.3} \quad n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b$$

Esta expresión puede ser escrita en forma matricial

$$\text{Ecuación 6.4} \quad n = W_p + b$$

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 6.11, puede resultar inapropiada y se prefiere emplear la notación abreviada representada en la figura 6.12

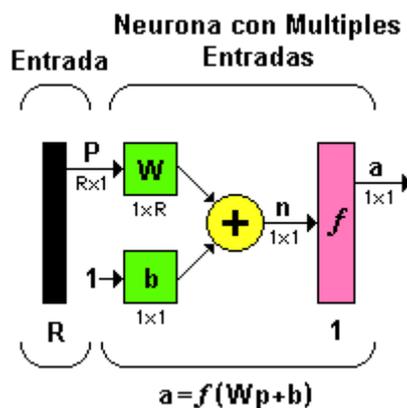


Figura 6.12: Neurona con múltiples entradas, notación abreviada

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 $R \times 1$, 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 6.13 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.

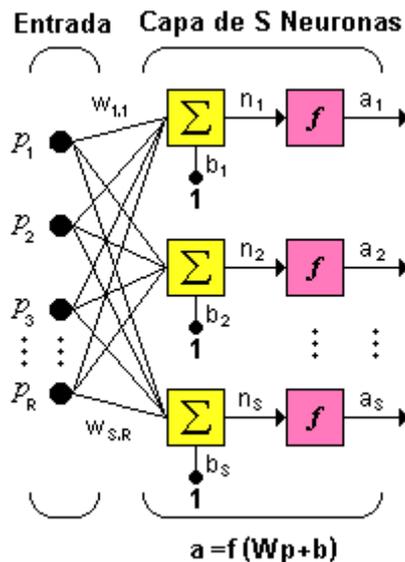


Figura 6.13: Capa de S neuronas. La capa incluye la matriz de pesos, los sumadores, el vector de ganancias, la función de transferencia y el vector de salida

En la figura 6.13 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 $S \times R$ 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 6.14 y 6.15, respectivamente.

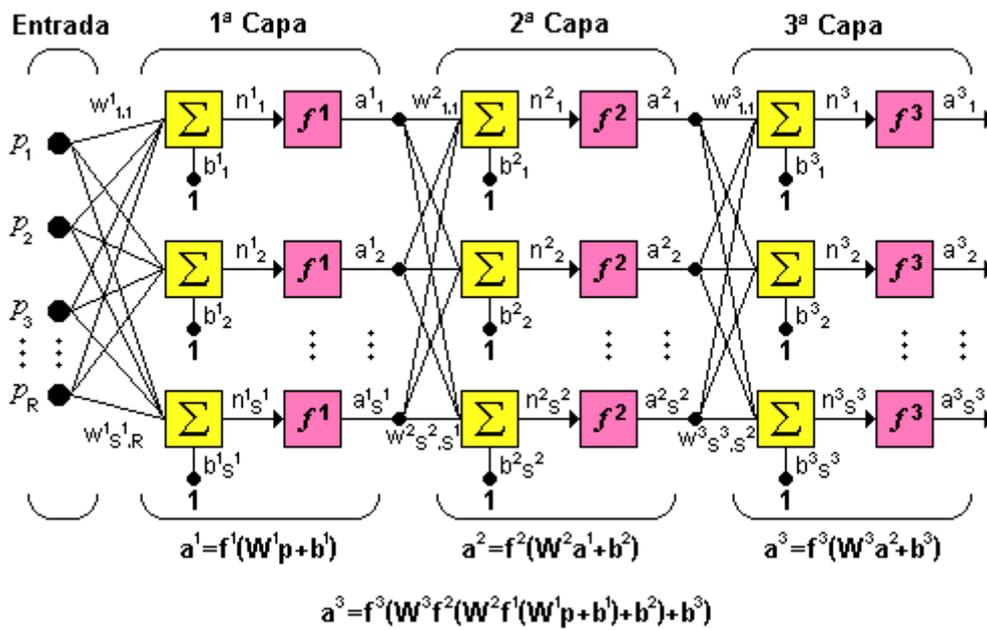


Figura 6.14: Red de tres capas

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 $S^1 \times S^2$

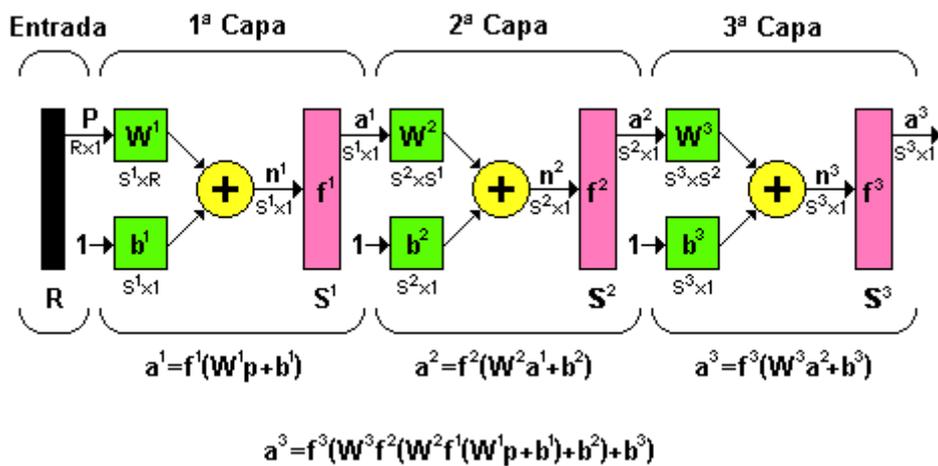


Figura 6.15: Red de tres capas con notación abreviada

Las redes multicapa son más poderosas que las redes de una sola capa, por ejemplo, una red de dos capas que tenga una función sigmoideal 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 6.16.

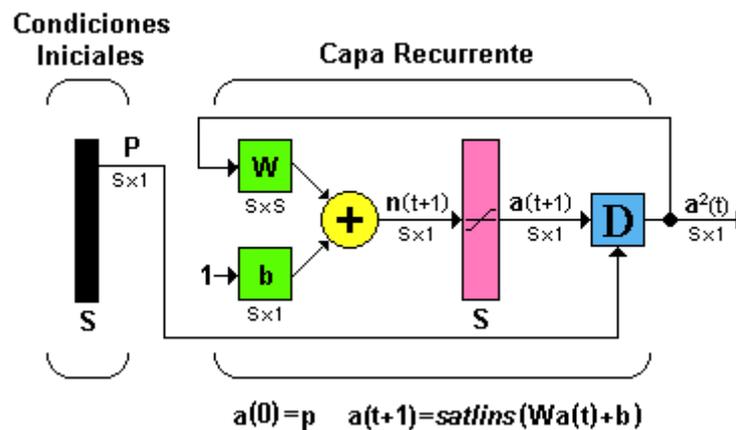


Figura 6.16: Redes Recurrentes

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

$$\text{Ecuación 6.5} \quad a(1) = \text{satlins}(Wa(0) + b), \quad a(2) = \text{satlins}(Wa(1) + b)$$

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 6.17 y el bloque integrador de la figura 6.18

- Retardo

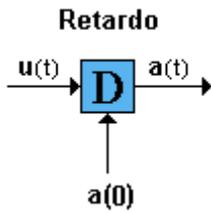


Figura 6.17: Bloque de retardo

Ecuación 6.6 $a(t) = u(t - 1)$

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

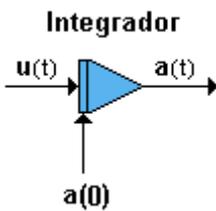


Figura 6.18: Bloque integrador

La salida del integrador es calculada de acuerdo a la expresión

Ecuación 6.7 $a(t) = \int_0^t u(\tau) d\tau + a(0)$

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); [1] un resumen de esta clasificación se observa en la tabla 6.2.

Tabla 6.2: Clasificación de las Redes Neuronales según tipo de aprendizaje y arquitectura

Aprendizaje	Arquitectura	
	Unidireccional	Realimentada
Supervisado	Perceptrón Adalina Madalina Perceptrón multicapa GRNN LVQ Máquina de Boltzmann	BSB Fuzzy Cog. Map
No supervisado	LAM OLAM Mapas de Kohonen Neocognitrón	ART Hopfield BAM
Híbridos	Función de base radial (RBF)	
Reforzados	Contrapropagación Aprendizaje reforzado	

Adalina: *adaptive linear neuron*; Madalina: *many adalinas*; GRNN: *general regression neural network*; LVQ: *learning vector quantization*; BSB: *brain state in a box*; LAM: *linear associative memory*; OLAM: *optimal LAM*; ART: *adaptive resonance theory*, y BAM: *bidirectional associative memory*.

6.4.4 Aprendizaje de las Redes Neuronales

Una RNA puede aprender de varias formas. La principal finalidad es que dado un determinado conjunto de entradas, se produzca un conjunto esperado de salidas, para realizar tal tarea, existen métodos para determinar la fuerza de las conexiones de la red.

Una manera es definir y atribuir explícitamente los pesos a cada una de las conexiones de la RNA, usando el conocimiento de un experto, como en el caso de las redes bidireccionales. Otra forma es entrenar a la red con un algoritmo de entrenamiento, que ira automáticamente ajustando los pesos de la red. Para el entrenamiento, existen dos técnicas, el aprendizaje supervisado y el aprendizaje no supervisado.

a) *Aprendizaje supervisado*: En el aprendizaje supervisado, se presenta a la red pares de entradas y salidas, donde las entradas llevarán a la red a producir una salida, que será comparada con la salida deseada, ver siguiente figura.

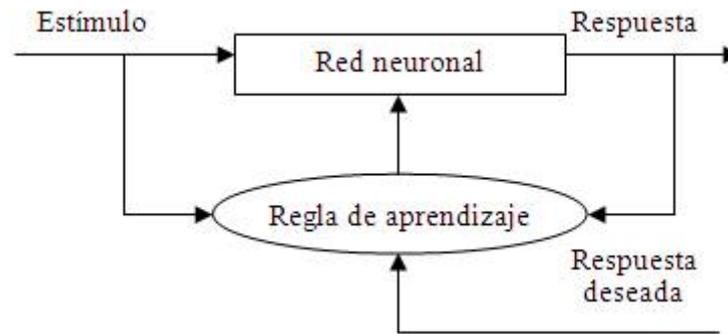


Figura 6.19: Aprendizaje supervisado

En caso que la respuesta producida por la red sea diferente de la respuesta esperada, la red genera un error, éste se usa para calcular el ajuste de los pesos sinápticos. Los pesos son alterados para aproximar los resultados de las salidas esperadas. Ese proceso se repite con todo el conjunto de entrenamiento, hasta que la red obtenga un error aceptable o ningún error. Al final del entrenamiento, cuando el aprendizaje de la red no converge, se aumenta el número de épocas de entrenamiento, alterar el número de neuronas de cada capa o el número de capas de la red.

b) *Aprendizaje no supervisado*: Se presenta a la red sólo las entradas, dejando de lado las salidas deseadas. Se utiliza un esquema tal que, para ejemplo de cosas semejantes, la red responde de modo semejante. La red se encamina iterativamente, en un proceso interno, propio de categorización de la información de entrada, también conocido como "*data clustering*", donde los datos de entrada son clasificados en categorías en las salidas.

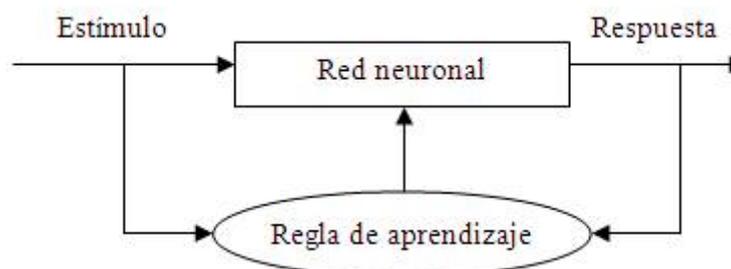


Figura 6.20: Aprendizaje no supervisado

Indicaciones prácticas acerca de la aplicación de una red

El desarrollo de una RNA necesita planificarse adecuadamente para conseguir una red convenientemente entrenada que alcance una precisión óptima. A modo indicativo, en la figura 6.21 se muestra un esquema básico de actuación y a continuación una breve descripción de los diferentes pasos representados 1-6.

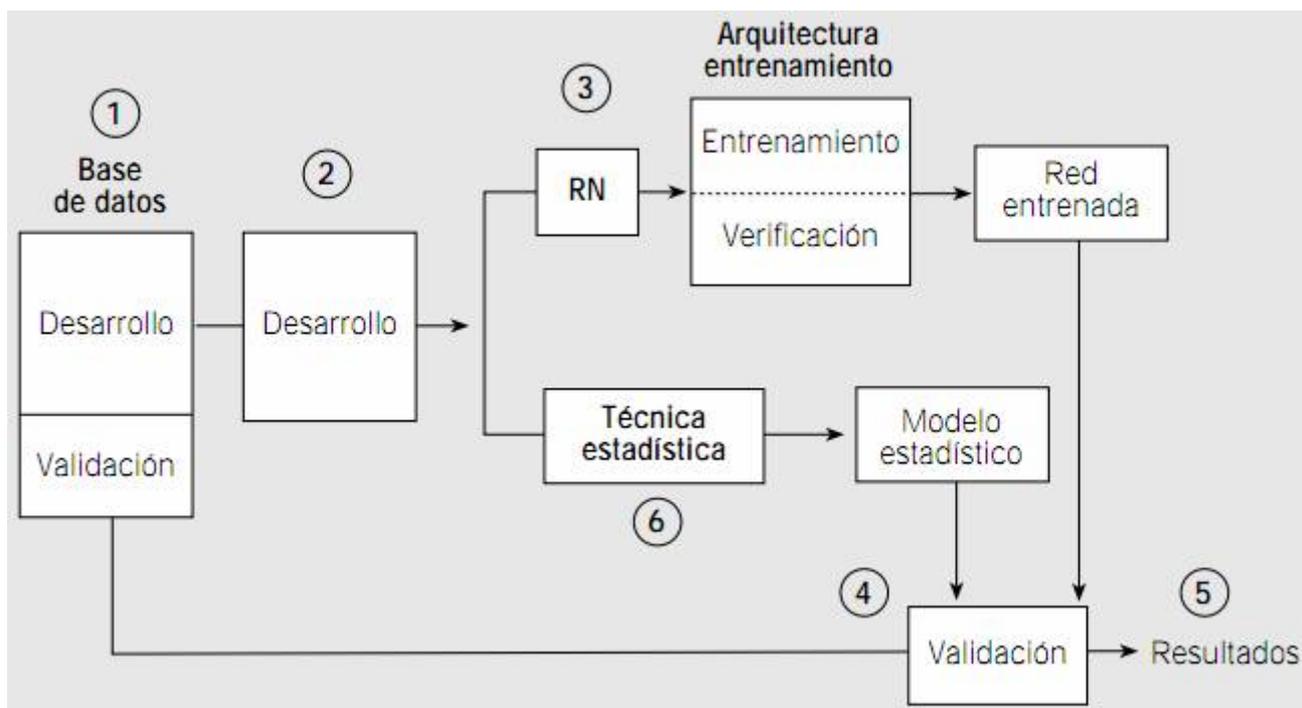


Figura 6.21: Secuencia del desarrollo de una aplicación basada en red neuronal artificial. RN: Red Neuronal Artificial

Paso 1: base de datos adecuada

El resultado obtenido con una RNA depende de los datos que se utilizan para su entrenamiento y, por lo tanto, los sesgos de muestreo pueden influir negativamente el resultado.

Paso 2: conjuntos de entrenamiento, verificación y validación

La partición de la serie de datos en los conjuntos de desarrollo (entrenamiento y verificación) y el correspondiente conjunto de validación, determina que el tamaño muestral sea suficientemente grande

Paso 3: construcción y entrenamiento de la red

Las características de las redes neuronales determinan que su utilización requiera de programas informáticos adecuados. En este punto, existen múltiples opciones comerciales y de libre distribución

Paso 4: validación de la red

Debe comprobarse la capacidad de generalización de la red enfrentándola a datos distintos de los utilizados en su entrenamiento (conjunto de validación).

Paso 5: evaluación de los resultados (precisión de la red)

Para comprobar la calibración (exactitud del modelo comparando la probabilidad esperada y la observada) se utilizan las pruebas de bondad de ajuste de Hosmer-Lemeshow que permiten evaluar las curvas de calibración correspondientes a los resultados del método.

Paso 6: comparación de los resultados entre redes neuronales artificiales y regresión logística

6.5 Principales tipos de redes neuronales

6.5.1 Perceptrón

6.5.1.1 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 6.22 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.

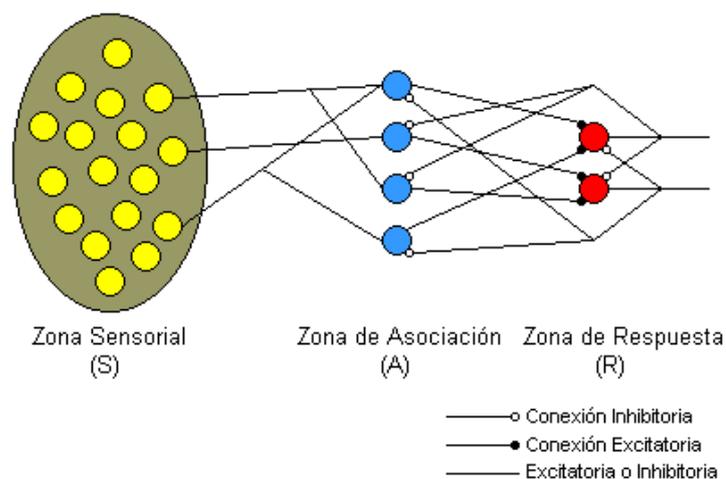


Figura 6.22: Modelo del Fotoperceptrón de Rosenblatt

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 6.23

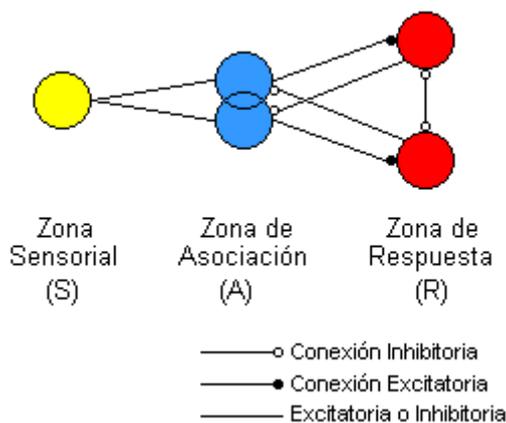


Figura 6.23: Esquema de conexiones de un Perceptrón sencillo

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" [8], 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 6.24.

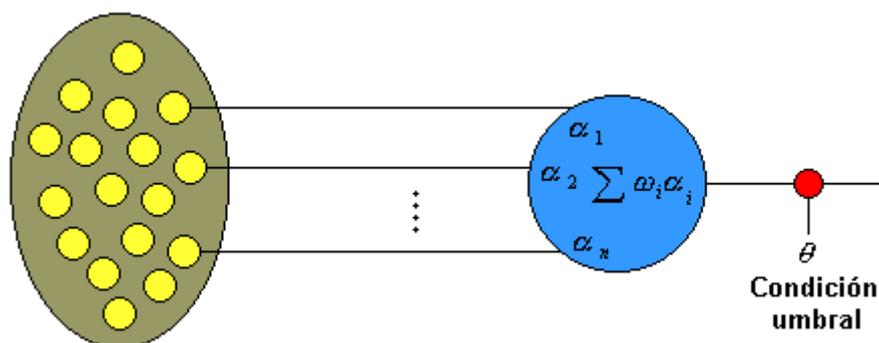


Figura 6.24: Perceptrón según Minsky y Papera

La estructura de un Perceptrón sencillo es similar a la del elemento general de procesamiento que se muestra en la figura 6.24; 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 6.24 es llamada función umbral o función de transferencia

$$\text{Ecuación 6.8} \quad f(\text{salida}) = \begin{cases} 1 & \text{si salida} \geq \theta \\ 0 & \text{si salida} < \theta \end{cases}$$

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.

6.5.1.2 Estructura de la red:

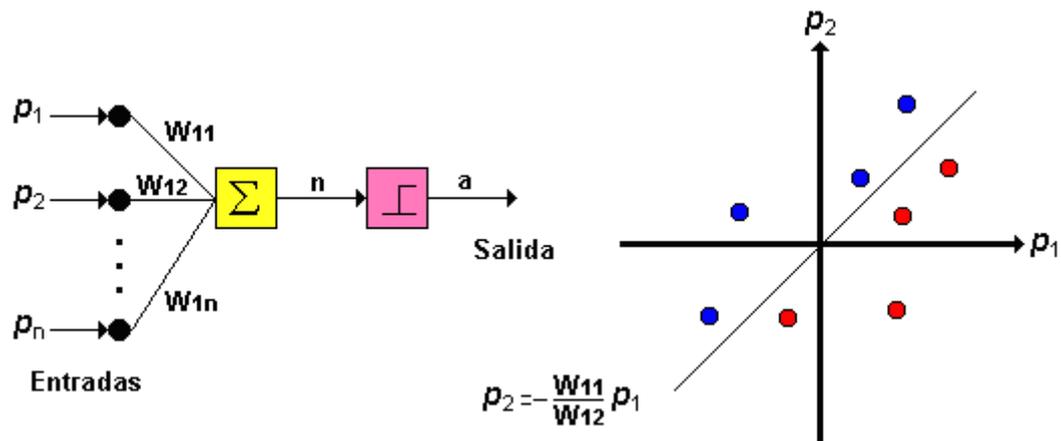


Figura 6.25: Perceptrón

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 6.25), 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.

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

$$\text{Ecuación 6.9} \quad a_i = \text{hardlim}(\eta_i) = \text{hardlim}(w_i^T p_i)$$

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.

Dentro de las redes supervisadas unidireccionales, la estructura más utilizada es el llamado perceptrón multicapa (MLP, multilayered perceptron). La arquitectura típica de este tipo de red está constituida por varias capas de nodos con interconexión completa entre ellos. El caso más sencillo en este tipo de red consiste en sólo 2 capas de neuronas, las de entrada y las de salida. De esta manera, podemos obtener un modelo adecuado para problemas lineales del tipo de la regresión lineal múltiple. Si queremos analizar problemas no-lineales, es necesario incorporar otras capas de neuronas intermedias u ocultas (hidden units), se representa en la figura 6.26.

En este tipo de red, una neurona recibe distintas entradas y activa una función de red (o regla de propagación) con unos pesos de entrada asociados. La computación de estos pesos se sigue de la aplicación de la función de activación que determina el nivel de activación de salida de la neurona. La entrada de las neuronas de la primera capa (entrada) son los valores de las variables predictoras y los niveles de activación de las neuronas de la última capa (salida) son los resultados de la red. Dentro de los parámetros que definen una red, la función de red más utilizada es de tipo lineal, y como función de activación más empleada está la función sigmoidea.

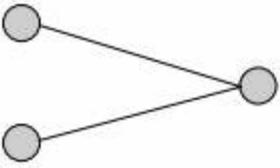
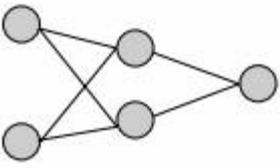
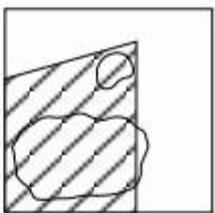
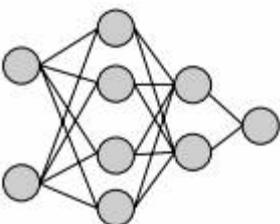
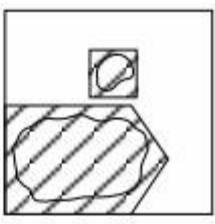
Capas			Decisión	Regiones en el plano
Entrada	Ocultas	Salida		
			Dos regiones	
			Regiones polinomiales	
			Regiones arbitrarias	

Figura 6.26: Capacidad de decisión de las redes neuronales artificiales (perceptrón multicapa). Con 2 variables de entrada, ante un problema de clasificación complejo en el plano (*) una red sin capa oculta no puede resolverlo; el aumento en el número de capas y nodos ocultos permite encontrar la solución.

6.5.2 Adaline

6.5.2.1 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

$$\text{Ecuación 6.10} \quad a = W^T p$$

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.

6.5.2.2 Estructura de la red:

La estructura general de la red tipo Adaline puede visualizarse en la figura 6.27.

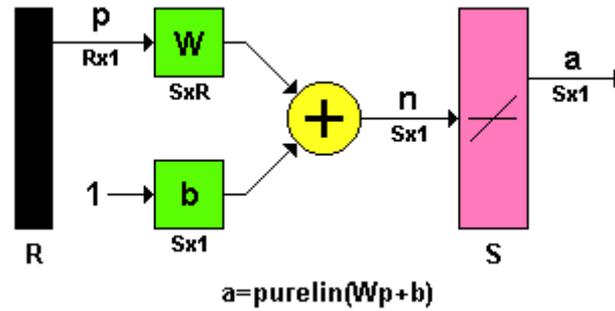


Figura 6.27: Estructura de una red Adaline

La salida de la red está dada por:

$$\text{Ecuación 6.11} \quad a = \text{purelin}(Wp + b) = Wp + b$$

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

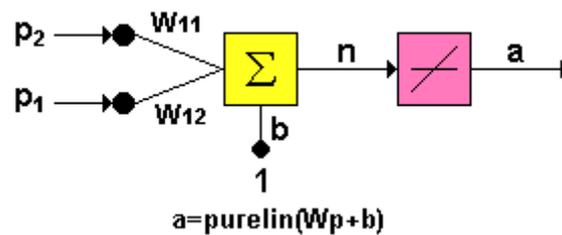


Figura 6.28: Adaline de una neurona y dos entradas

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

$$\text{Ecuación 6.12} \quad W^T p + b = 0$$

especifica la línea que separa en dos regiones el espacio de entrada, como se muestra en la figura 6.29

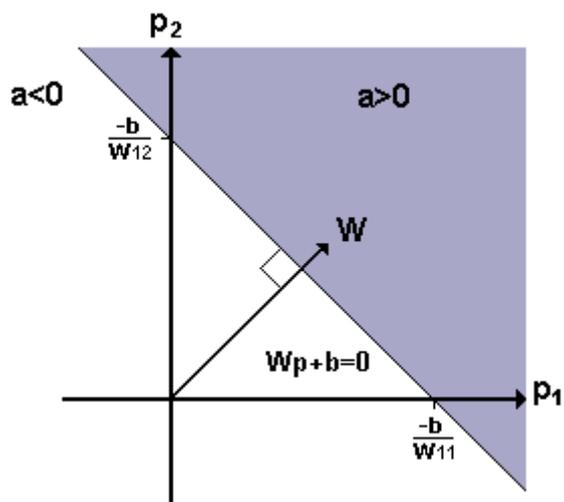


Figura 6.29: Característica de decisión de una red tipo Adaline

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.

6.5.3 Backpropagation

6.5.3.1 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 llevó al surgimiento de las redes multicapa para superar 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 [19].

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.

6.5.3.2 Estructura de la Red:

La estructura típica de una red multicapa se observa en la figura 6.30

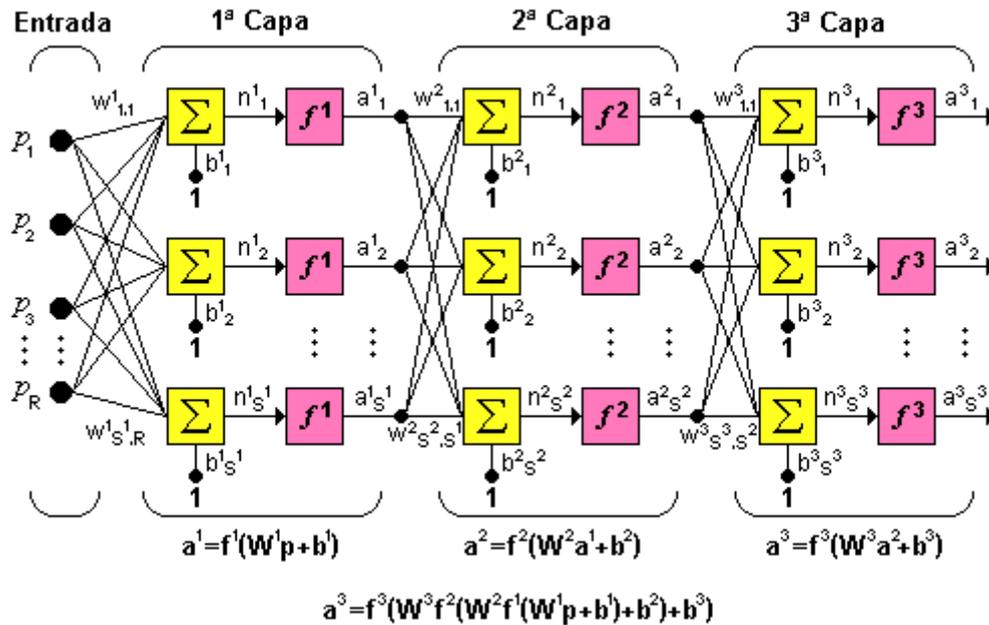


Figura 6.30: Red de tres capas

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 6.29, 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:

Ecuación 6.13 $R : S^1 : S^2 : S^3$

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

La notación de la figura 6.31 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 6.30.

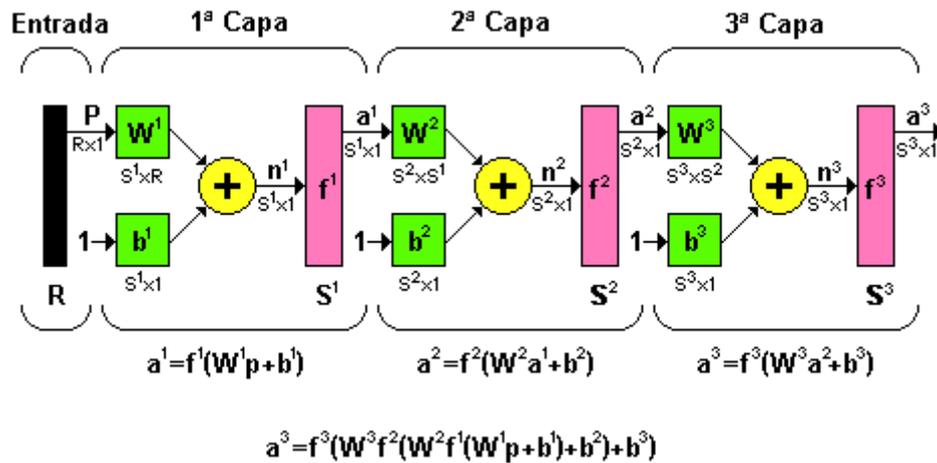


Figura 6.31: Notación compacta de una red de tres capas

6.5.3.3 Regla de Aprendizaje

El algoritmo Backpropagation para redes multicapas [13] 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:

$$\text{Ecuación 6.14} \quad \{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_o, t_o\}$$

Donde p_o es una entrada a la red y t_o 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 específico, 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.

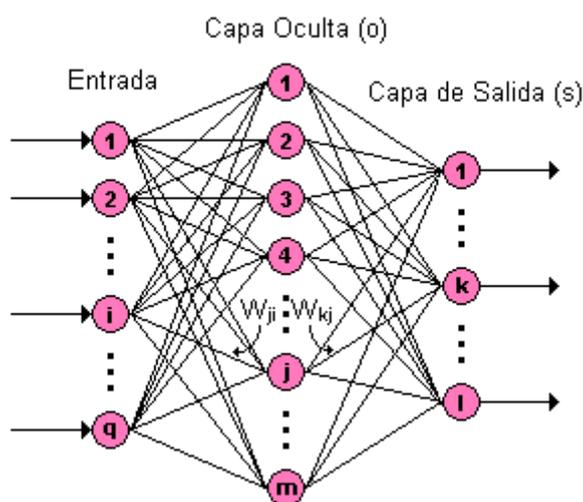


Figura 6.32: Disposición de una red sencilla de 3 capas

Es importante aclarar que en la figura 6.32:

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 6-15

$$\text{Ecuación 6.15} \quad \rho = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \cdot \\ \cdot \\ \rho_i \\ \cdot \\ \cdot \\ \rho_q \end{bmatrix}$$

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 6-16, nótese que la entrada neta es el valor justo antes de pasar por la función de transferencia

$$\text{Ecuación 6.16} \quad n_j^o = \left(\sum_{i=1}^q W_{ji}^o \rho_i + b_j^o \right)$$

W_{ji}^o : Peso que une la componente i de la entrada con la neurona j de la capa oculta

ρ_i : Componente i del vector ρ que contiene el patrón de entrenamiento de q componentes

b_j^o : 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_j^o que esta dada por la ecuación 6-17

$$\text{Ecuación 6.17} \quad a_j^o = f^o \left(\sum_{i=1}^q W_{ji}^o \rho_i + b_j^o \right)$$

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

Las salidas a_j^o 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 está descrito por la ecuación 6-18

$$\text{Ecuación 6.18} \quad n_k^s = \left(\sum_{j=1}^m W_{kj}^s a_j^o + b_k^s \right)$$

W_{kj}^s : 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_j^o : Salida de la neurona j de la capa oculta, la cual cuenta con m neuronas.

b_k^s : Ganancia de la neurona k de la capa de salida.

n_k^s : Entrada neta a la neurona k de la capa de salida

La red produce una salida final descrita por la ecuación 6-19

$$\text{Ecuación 6.19} \quad a_k^s = f^s(n_k^s)$$

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

Reemplazando 6-18 en 6-19 se obtiene la salida de la red en función de la entrada neta y de los pesos de conexión con la última capa oculta

$$\text{Ecuación 6.20} \quad a_k^s = f^s \left(\sum_{j=1}^m W_{kj}^s a_j^o + b_k^s \right)$$

La salida de la red de cada neurona a_k^s se compara con la salida deseada t_k para calcular el error en cada unidad de salida 6-21

$$\text{Ecuación 6.21} \quad \delta_k = (t_k - a_k^s)$$

El error debido a cada patrón p propagado está dado por 6-22

$$\text{Ecuación 6.22} \quad ep^2 = \frac{1}{2} \sum_{k=1}^s (\delta_k)^2$$

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 6-23

$$\text{Ecuación 6.23} \quad e^2 = \sum_{p=1}^r ep^2$$

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:

$$\text{Ecuación 6.24} \quad W_{k+1} = W_k - \alpha \nabla ep^2$$

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:

$$\text{Ecuación 6.25} \quad -\frac{\partial ep^2}{\partial W_{kj}^s} = -\frac{\partial}{\partial W_{kj}^s} \left(\frac{1}{2} \sum_{k=1}^l (t_k - a_k^s)^2 \right) = (t_k - a_k^s) \times \frac{\partial a_k^s}{\partial W_{kj}^s}$$

$-\frac{\partial ep^2}{\partial W_{kj}^s}$: 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_{kj}^s

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 6-19 puede verse que la salida de la red a_k^s esta explícitamente en función de n_k^s y de la ecuación 6-18 puede verse que n_k^s esta explícitamente en función de W_{kj}^s , considerando esto se genera la ecuación 6-25

$$\text{Ecuación 6.26} \quad \frac{\partial a_k^s}{\partial W_{kj}^s} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s}$$

Tomando la ecuación 6-26 y reemplazándola en la ecuación 6-25 se obtiene,

$$\text{Ecuación 6.27} \quad -\frac{\partial ep^2}{\partial W_{kj}^s} = (t_k - a_k^s) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial W_{kj}^s}$$

$\frac{\partial n_k^s}{\partial W_{kj}^s}$: 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 6-27 las derivadas de las ecuaciones 6-18 y 6-19 se obtiene

$$\text{Ecuación 6.28} \quad -\frac{\partial ep^2}{\partial W_{kj}^s} = (t_k - a_k^s) \times f^{1s}(n_k^s) \times a_j^o$$

Como se observa en la ecuación 6-28 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 $f^{1s}(n_k^s)$ es requerido para el cálculo del error.

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

Ecuación 6.29 *logsig*:

$$f(n) = \frac{1}{1 + e^{-n}} ; f'(n) = f(n)(1 - f(n)) ; f''(n) = a(1 - a)$$

$$\text{Ecuación 6.30} \quad \text{tansig: } f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} ; f'(n) = 1 - (f(n))^2 ; f''(n) = -2f(n)$$

$$\text{Ecuación 6.31} \quad \text{purelin: } f(n) = n; f'(n) = 1$$

De la ecuación 6-28, los términos del error para las neuronas de la capa de salida están dados por la ecuación 6-32, la cual se le denomina comúnmente sensibilidad de la capa de salida.

$$\text{Ecuación 6.32} \quad \delta_k = (t_k - a_k^s) f'^s(n_k^s)$$

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 6-32 se procede a encontrar el error en la capa oculta el cual está dado por:

$$\text{Ecuación 6.33} \quad -\frac{\partial \epsilon p^2}{\partial W_{ji}^o} = -\frac{\partial}{\partial W_{ji}^o} \left(\frac{1}{2} \sum_{k=1}^l (t_k - a_k^s)^2 \right) = \sum_{k=1}^l (t_k - a_k^s) \times \frac{\partial a_k^s}{\partial W_{ji}^o}$$

Para calcular el último término de la ecuación 6-33 se debe aplicar la regla de la cadena en varias ocasiones como se observa en la ecuación 6-34 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

$$\text{Ecuación 6.34} \quad \frac{\partial a_k^s}{\partial W_{ji}^o} = \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o}$$

Todos los términos de la ecuación 6-35 son derivados respecto a variables de las que dependen explícitamente, reemplazando 6-34 en 6-33 tenemos:

$$\text{Ecuación 6.35} \quad -\frac{\partial \epsilon p^2}{\partial W_{ji}^o} = \sum_{k=1}^l (t_k - a_k^s) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial a_k^o} \times \frac{\partial a_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o}$$

Tomando las derivas de las ecuaciones 6-16, 6-17, 6-18, 6-19 y reemplazándolas en la ecuación 6-35 se obtiene la expresión del gradiente del error en la capa oculta

$$\text{Ecuación 6.36} \quad -\frac{\partial \epsilon p^2}{\partial W_{ji}^o} = \sum_{k=1}^l (t_k - a_k^s) \times f'^s(n_k^s) \times W_{kj}^s \times f'^o(n_j^o)$$

Reemplazando la ecuación 6-32 en la ecuación 6-36 se tiene:

$$\text{Ecuación 6.37} \quad -\frac{\partial \epsilon p^2}{\partial W_{ji}^o} = \sum_{k=1}^l \delta_k \times W_{kj}^s \times f'^o(n_j^o) \times p_i$$

Los términos del error para cada neurona de la capa oculta esta dado por la ecuación 6-38, este término también se denomina sensibilidad de la capa oculta

$$\text{Ecuación 6.38} \quad \delta_j^o = f'^o(n_j^o) \times \sum_{k=1}^l \delta_k^s W_{kj}^s$$

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 6-39 y 6-40.

$$\text{Ecuación 6.39} \quad W_{kj}(t+1) = W_{kj}(t) - 2\alpha \delta_k^s$$

$$\text{Ecuación 6.40} \quad b_k(t+1) = b_k(t) - 2\alpha \delta_k^s$$

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 6-41 y 6-42

$$\text{Ecuación 6.41} \quad W_{ji}(t+1) = W_{ji}(t) - 2\alpha \delta_j^o p_i$$

$$\text{Ecuación 6.42} \quad b_j(t+1) = b_j(t) - 2\alpha \delta_j^o$$

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 [9], la cual es una extensión de la regla delta desarrollada por Widrow [10] en 1930.

Para algunos autores las sensibilidades de las capas están denotadas por la letra S , reescribiendo las ecuaciones 6-32 y 6-38 con esta notación se obtienen las ecuaciones 6-43 y 6-44.

$$\text{Ecuación 6.43} \quad S^M = -2f^M(n^M)(t - a)$$

$$\text{Ecuación 6.44} \quad S^M = f^m(n^m)(W^{m+1})^T s^{m+1}, \text{ para } m = M - 1, \dots, 2, 1.$$

En la ecuación 6-43, M representa la última capa y S^M la sensibilidad para esta capa, la ecuación 6-44 expresa el cálculo de la sensibilidad capa por capa comenzando desde la última capa oculta, cada uno de estos términos involucra que el término para la sensibilidad 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 sensibilidad.

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 tasa 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 6.33

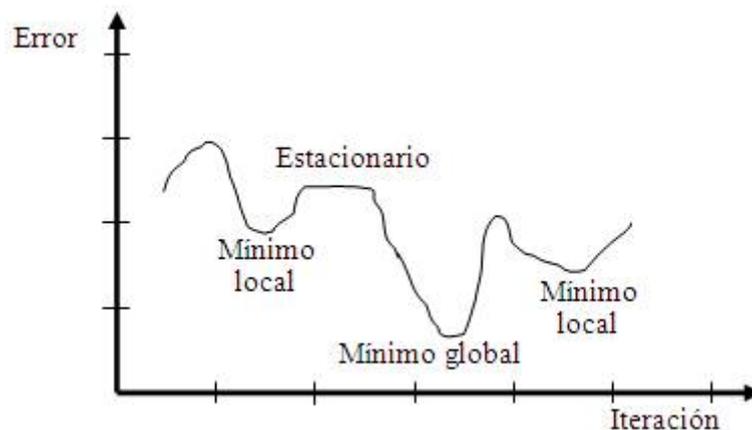


Figura 6.33: Superficie típica de error

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 [17], 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:

$$\text{Ecuación 6.45} \quad t = \sin \frac{\pi}{4} \rho \quad \text{para el intervalo} \quad -2 \leq \rho \leq 2$$

La función se ha restringido al intervalo entre -2 y 2 para conservarla dentro de límites observables, como se observa en la figura 6.34

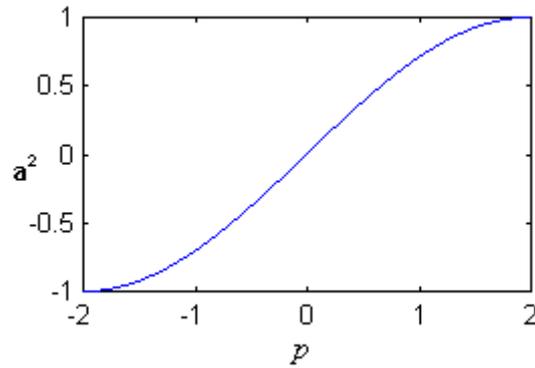


Figura 6.34: Intervalo de la función t

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 6.35

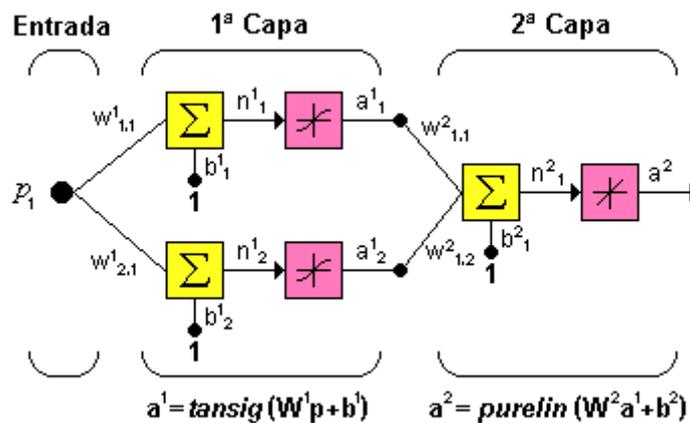


Figura 6.35: Red utilizada para aproximar la función

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

$$\text{Ecuación 6.46} \quad a^1 = \text{tansig}(W^1 p^T + b)$$

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.

$$\text{Ecuación 6.47} \quad a^2 = \text{purelin}(W^2 \times a^1 + b^2)$$

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 [12].

El diagrama mostrado en la Figura 6.36 muestra la secuencia de pasos necesarios para la implementación del algoritmo de entrenamiento Backpropagation.

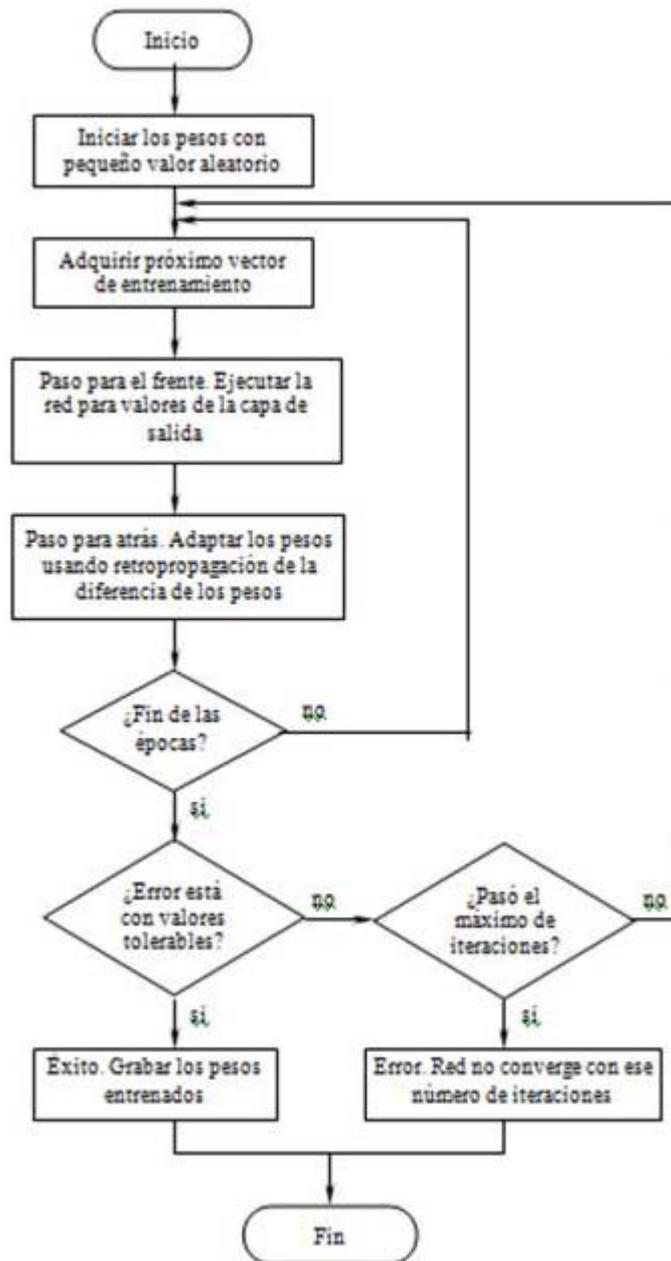


Figura 6.36: Diagrama de flujo del algoritmo backpropagación.

6.6 REFERENCIAS

- [1]: Med Clin (Barc) 2004;122(Supl 1):59-67
- [2] 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
- [3] Acosta M.I., Zuluaga C.A. Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web, 2000
- [4] Jud J.S. Neural network design and the complexity of learning, ISBN 0-262-10045-2, 1990
- [5] Schuster, H.G., Applications of Neural Networks. ISBN: 3527290109, 1992
- [6] Bishop, C.M. Neural networks for pattern recognition, ISBN13: 9780195667998; ISBN10 0195667999, 2009
- [7] Matías J.M, Redes Neuronales para regresión y clasificación. Nuevos algoritmos y aplicaciones. ISBN: 84-688-8028-0, 2004
- [8] Minsky M., Papert S. Perceptrons. ED MIT, 1969
- [9] Rumelhart D. y Zisper D. Feature discover y competitive learning. Cognitive Science #9 pp 74-115, 1985
- [10] 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.
- [11] A review on the young history of the wind power short-term prediction Alexandre Costaa,_, Antonio Crespob, Jorge Navarroa, Gil Lizcanoc, Henrik Madsend, Everaldo Feitosae. CONDORI, F., (2001). Sistema Híbrido Neurodifuso para la Evaluación de la Calidad del Software en un Proceso de Auditoría Informática. Revista de la Sociedad Peruana de Ciencias de la Computación.
- [12] Jacobs RA. Increased rated of convergence through learning rate adaptation. Neural Network. Vol1 #4, pp 294-308, 1988
- [13] Fukushima K. Cognitron: A self organizing multilayered neural network. Biological cybernetics. #20 pp 121-136, 1975
- [14] FAUCET, L., (1994). Fundamental of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall International Inc, New Jersey. 296p.
- [15] LAUDON, K., y LAUDON, J., (2000). Management Information Systems, Organization and Technology. Cuarta Edición, Editorial Prentice Hall Hispanoamericana..

- [16] PANDYA, A., y MACY, R., (1996). Pattern Recognition with Neural Networks in C++. CRC Press, Boca Raton, Florida. USA.
- [17] RUMELHART, D., *et al.*, (1986). Learning Internal Representations by Error Propagation. The MIT Press, Cambridge, Massachusetts. USA.
- [18] SANTÍN, G., (2000). Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares Mediante Redes Neuronales. Universidad Complutense de Madrid. España. 40p.
- [19] SELLÉS, M., (2001). Optimización de una Batería de Pruebas Mediante una Red Neuronal Artificial. Editorial Omega. 289p.
- [20] Eduardo Francisco Caicedo, Jesús Alfonso López. Una aproximación práctica a las Redes Neuronales Artificiales. 2009. Editorial U. del Valle.
- [21] Bonifacio Martón del Brío, Alfredo Sanz Molina. Redes Neuronales y Sistemas Difusos. 2ª Edición. Editorial AlfaOmega & Ra-Ma.
- [22] Pedro Ponce Cruz. Inteligencia Artificial con Aplicaciones a la Ingeniería. Editorial AlfaOmega.

CAPÍTULO 7

Influencia de la fiabilidad en la predicción a corto plazo de la potencia eléctrica producida por un parque eólico, en el coste de generación por MWh y en la planificación de las áreas eólicas. Un caso de estudio en las islas Canarias

INDICE

7.1 Introducción.....	222
7.2 Metodología.....	225
7.3 Datos Meteorológicos usados.....	230
7.4 Cálculos y análisis de resultados.....	231
7.4.1 Coste económico del desvío entre la potencia medida y la predicha.....	234
7.4.2 Estructura de coste de la energía generada por un aerogenerador.....	237
7.4.3 Precio de la Energía Eléctrica.....	238
7.4.4 Análisis de resultados.....	240
7.5 Los sistemas de hidrobombeo reversibles como medio para la gestión de los excedentes o déficits de energía eléctrica de origen eólica.....	246
7.6 Conclusiones.....	246
7.7 Referencias.....	248

INDICE DE FIGURAS:

Figura 7.1: Localización de las estaciones meteorológicas usadas (Velázquez et al., 2011b)

Figura 7.2: Distribuciones horarias medias porcentuales de la potencia eólica para cada uno de los meses del año

Figura 7.3: Distribución de la densidad de la potencia eólica media mensual

Figura 7.4: Distribución relativa porcentual de la energía eólica mensual

Figura 7.5: Coste medio mensual de la energía desviada

Figura 7.6: Precios de venta medios mensuales de la energía eléctrica (€/MWh)

Figura 7.7: Contribución del coste de desvío al coste de producción de la energía eléctrica por un aerogenerador

Figura 7.8: Coste total de producción de la energía eléctrica generada por un aerogenerador (COE)

Figura 7.9: Relación existente entre el coste de desvío específico (Cde) y los ingresos por Mwh(Pre)

Figura 7.10: Variación del rendimiento de la energía normalizada función del valor del NMAE

INDICE DE TABLAS:

Tabla 7.1: Coste medio horario, para cada mes, de la energía desviada (€/MWh)

Tabla 7.2: Evolución del precio medio aritmético de la energía eléctrica en el mercado libre español

7.1 Introducción

Los objetivos estratégicos que se han establecido para el horizonte del año 2020, para la Unión Europea en general y para España y las islas Canarias en particular [1-4], en relación a la contribución que debe tener la energía eólica en la demanda de la energía eléctrica, generará un incremento notable de la potencia eólica a instalar en dicho horizonte temporal.

Para poder llevar a cabo una integración a gran escala de la energía eólica en los sistemas eléctricos, es preciso disponer de herramientas avanzadas que posibiliten la realización de pronósticos fiables del recurso eólico con suficiente antelación tanto en el largo plazo (10 o más años) [5-10] como en el corto plazo (hasta 48 horas) [11-16].

En los procesos de compra-venta de energía en los mercados eléctricos es necesario conocer la programación de las ofertas de generación para periodos futuros de hasta 48 horas [17-21]. Este aspecto es aún más acuciante en el marco de un mercado eléctrico liberalizado, donde el disponer de pronósticos acertados permite un posicionamiento favorable de la energía eólica frente a otras formas más convencionales de generación de energía eléctrica. Más aún en sistemas eléctricos débiles, como pueden ser los presentes en la archipiélago canario (España), formado por siete islas principales y donde cada una de éstas cuenta con un sistema eléctrico independiente [22]. Por ello, y dada la variabilidad en el tiempo (diaria, estacional, interanual) de las características del viento [23-29], se hace preciso el disponer de modelos de predicción a muy corto plazo (inferior a 48 horas) de la potencia eléctrica de los parques eólicos [11-16].

En la literatura científica se han publicados diferentes modelos para la predicción futura de la potencia eólica basados en diferentes metodologías [11-16].

Los diferentes modelos presentan diversas fiabilidades o errores en la estimación, ello da lugar a que los valores predichos, en muchos casos, disten en gran medida de los valores reales medidos.

Con el objeto de optimizar los resultados en la predicción futura de la energía eólica a corto plazo, se han desarrollado diferentes trabajos orientados a comparar diferentes herramientas de predicción existentes en la actualidad. El objetivo de estos trabajos es aprovechar las potencialidades de cada una de dichas herramientas de predicción y poder así generar otras nuevas que mejoren las existentes. Dentro de los trabajos desarrollados en este sentido se encuentra el proyecto ANEMOS [30-32] y el Ejercicio de Predicción [33]. Entre las diversas conclusiones extraídas de dichos estudios se encuentra que los errores de predicción medios relativos a la potencia nominal de parque eólico, NMAE, oscilan entre el 10% para terrenos planos y el 21% para terrenos muy complejos [30-33]. Los resultados obtenidos son medias relativas a todos los modelos de predicción que se han utilizados en estos estudios y para horizontes temporales de predicción de entre 1 y 48 horas. Es por ello que se ha valorado también la desviación estándar del error, relativa a la potencia nominal del parque eólico, NSDE. Ésta desviación alcanza un valor medio del 20% [31]. Por lo tanto, para el caso más desfavorable de terrenos complejos, el error en la predicción futura de la potencia eléctrica de un parque eólico será inferior al 61% $(\overline{\text{NMAE}} + 2 \times \text{NSDE})$, con una probabilidad del 97,5%. Donde $\overline{\text{NMAE}}$ es el valor medio de los errores obtenidos con los diferentes modelos, en los diferentes parques eólicos y horizontes temporales.

Para garantizar el suministro y la calidad de la energía eléctrica, el operador del sistema debe procurar que las redes eléctricas, que sirven de medio de distribución y transporte de la energía, sean capaces de gestionar las cantidades de ésta que se negocian en el mercado. Las transacciones energéticas de un día cualquiera D son negociadas con antelación, generalmente el día D-1. Por lo tanto, es de vital importancia que las ofertas energéticas negociadas sean posteriormente las que se dispongan en el sistema eléctrico. Las posibles desviaciones que pueda haber en este sentido generarán problemas en dicho sistema eléctrico. El operador del mismo debe actuar de forma inminente para corregir las desviaciones de potencia y garantizar así la calidad en el suministrado de energía. Estas correcciones en el sistema eléctrico implican un coste adicional que es imputado directamente a aquellos productores que han generado el desvío [34-39].

Por tanto, los errores de predicción originados por la dificultad de estimar con una alta fiabilidad, la variabilidad inherente a la energía eólica y su escasa gestionabilidad son fuente de costes. Ese coste adicional será tanto mayor cuanto más elevado sea el desvío entre la potencia predicha y la medida. A ese coste se denominará, Coste de Desvío (Cd).

La estructura de costes de la generación de energía para un parque hasta ahora considerada en la literatura científica, contempla generalmente dos factores: los costes debidos a la inversión inicial y los costes de Operación y Mantenimiento [40-45].

En este capítulo se evaluará el coste de desvío medio por unidad de energía generada por un aerogenerador. Así mismo, se analizará la influencia del error cometido en la predicción de la potencia eólica en la magnitud del coste de desvío y en su contribución al coste total de producción. Se compararán los nuevos costes de producción, una vez incorporados los costes de desvíos, con los precios de venta medios de la energía establecidos en el mercado eléctrico.

La incorporación de los costes de desvío como un nuevo factor en la estructura de costes de generación, disminuirá la rentabilidad económica de las granjas eólicas. En este sentido, se deberá exigir un mayor potencial eólico a una zona determinada para poder rentabilizar un proyecto de parque eólico. En este documento se analizará el efecto negativo que tiene el coste de desvío en el potencial eólico de una zona determinada. Conocer este efecto es fundamental en la ordenación del territorio y en lo que respecta a la delimitación de zonas eólicas dentro de las planificaciones energéticas de las regiones.

Los cálculos realizados en este documento se han particularizado para el sistema y mercado eléctrico del archipiélago canario, regulados a su vez por los operadores del sistema y mercado eléctrico español.

7.2 Metodología

Como se ha señalado en el apartado anterior, el desvío existente entre la potencia eléctrica predicha y la medida implica un coste económico al sistema eléctrico. Dicho coste es imputado proporcionalmente a las fuentes de generación que provocan el desvío. Para el caso particular de los sistemas eléctricos españoles, los costes de desvíos se establecen para cada hora del año. El operador del sistema eléctrico español, Red Eléctrica de España, publica los costes por unidad de energía desviada (€/MWh) en su página Web [4].

En el estudio realizado en este documento, se ha partido de la información disponible de los costes de desvío de los años 2007 al 2011. Para cada uno de los meses del año se han calculado los costes de desvíos medios horarios en el periodo de los cinco años de estudio, Ecuación 7.1.

$$\text{Ecuación 7.1} \quad \overline{Cd_{h,m}} = \frac{1}{N_y \times N_d} \sum_{d=1}^{N_d} \sum_{y=1}^{N_y} Cd_{h,m,d,y}$$

Donde:

$\overline{Cd_{h,m}}$; Es el coste de desvío medio para la hora "h" del mes "m" dentro del periodo de estudio 2007-2011 (en Euros/MWh desviado)

$Cd_{h,m,d,y}$, Es el coste de desvío medio para la hora "h" del día "d", relativo al mes "m" y año "y"

N_y , Es el número de años del periodo de estudio

N_d , Es el número de días del mes considerado

La generación de energía eléctrica de origen eólico varía a lo largo de un día concreto dependiendo de la potencia eólica disponible para cada una de las horas del día, Ecuación 7.2 [23-29]. Por ello, se ha calculado el coste de desvío mensual, teniendo en cuenta la distribución horaria de la densidad de potencia eólica.

$$\text{Ecuación 7.2} \quad P_{h,m,d,y} = \frac{1}{2} \rho V_{h,m,d,y}^3$$

Donde:

$P_{h,m,d,y}$, Es la densidad de potencia eólica en la hora "h" del día "d", relativo al mes "m" y año "y" (in W/m²)

ρ , Es la densidad del aire (se ha escogido para los cálculos de este documento un valor igual a 1.225 Kg/m³)

$V_{h,m,d,y}$, Es la velocidad del viento en la hora "h" del día "d", relativo al mes "m" y año "y"

Para los cálculos realizados en este documento, se ha estimado una distribución horaria tipo de la densidad de potencia eólica. Los resultados se han particularizado para el caso del archipiélago canario. Por tanto, la información eólica utilizada se corresponde con estaciones meteorológicas instaladas en el mismo.

Las islas de Gran Canaria y Tenerife son las más pobladas y en ellas se encuentra el 80% del total de la potencia eléctrica instalada en el archipiélago. Asimismo, la mayoría de la potencia eólica instalada hasta el momento en el archipiélago se concentra en estas dos islas y se prevé que los mayores porcentajes de parques eólicos que se instalen en el futuro en canarias se llevarán a cabo en las mismas. Por este motivo, a la hora de estimar la distribución horaria por mes de la potencia eólica se ha ponderado ésta según sea la isla donde se encuentre la estación anemométrica de referencia.

Al igual que se describió para los costes de desvío, a partir de la información horaria de la potencia eólica para los 12 años disponibles (1999-2010), se ha estimado la densidad de potencia eólica media para cada una de las horas en cada uno de los meses del año, Ecuación 7.3.

Ecuación 7.3

$$\overline{P_{h,m}} = \frac{1}{N_{wy} \times N_d} \sum_{d=1}^{N_d} \sum_{y=1}^{N_{wy}} P_{h,m,d,y}$$

Donde:

$\overline{P_{h,m}}$, Es la densidad de potencia eólica media para la hora "h" del mes "m" (en W/m²)

$P_{h,m,d,y}$, Es la densidad de potencia eólica en la hora "h" del día "d", relativa al mes "m" y año "y"

N_{wy} , Es el número de años de los que se dispone de información eólica

N_d , Es el número de días del mes considerado

A partir de los resultados obtenidos para los costes de desvíos medios horarios por mes, Ecuación 7.1 y los de las densidades de potencias eólicas horarias medias por mes, Ecuación 7.3, se obtienen los valores del coste de desvío medio ponderado mensual.

Ecuación 7.4

$$\overline{Cd_m} = \frac{1}{\sum_{h=1}^{24} \overline{P_{h,m}}} \sum_{h=1}^{24} \overline{Cd_{h,m}} \times \overline{P_{h,m}}$$

Donde:

$\overline{Cd_m}$, Es el coste de desvío medio ponderado para el mes "m" (en Euros/MWh desviado)

A partir del cálculo de la densidad de potencia eólica media horaria por mes, Ecuación (7.3), se puede calcular la densidad de potencia eólica media y la densidad de energía eólica para cada uno de los meses del año (Ecuación 7.5 y Ecuación 7.6).

Ecuación 7.5

$$\overline{P_m} = \frac{1}{24} \sum_{h=1}^{24} \overline{P_{h,m}}$$

Donde:

$\overline{P_m}$, Es la densidad de potencia eólica media para el mes "m" (en W/m²)

Ecuación 7.6

$$E_m = \overline{P_m} \times N_{h,m}$$

Donde:

$E_{m,r}$, Es la densidad de energía eólica para el mes "m" (en Wh/m²)

$N_{h,m,r}$, Es el número de horas del mes "m"

Teniendo en cuenta que el recurso eólico no sólo fluctúa según la hora en un día sino que también varía durante los diferentes meses del año [23-29], se ha calculado el coste de desvío medio ponderado en el año de la forma que indica la Ecuación 7.7.

Ecuación 7.7

$$\overline{Cd} = \frac{1}{\sum_{h=1}^{12} E_m} \sum_{h=1}^{12} \overline{Cd}_m \times E_m$$

Donde:

\overline{Cd} , Es el coste de desvío medio en un año (en Euros/MWh desviado)

El coste de desvío medio calculado según la Ecuación 7.7, se refiere al coste por cada MWh que se desvíe el valor realmente medido del predicho.

Para calcular la implicación de dicho coste de desvío sobre la producción total del aerogenerador, ha de tenerse en cuenta el valor del error que se comente en la predicción. Los diferentes trabajos que se han desarrollado para comparar la diversidad de modelos de predicción de la potencia eléctrica futura de un parque [30-33], Ecuación 7.8.

Ecuación 7.8

$$NMAE = \frac{MAE}{P_n} \times 100$$

Donde:

NMAE, Error Absoluto Medio Normalizado

P_n , Es la potencia nominal de la granja eólica

MAE, Error Absoluto Medio. Viene definido por la Ecuación 7.9

Ecuación 7.9

$$MAE = \frac{1}{(48 \times N)} \sum_{i=1}^N \sum_{h=1}^{48} |P_f(t+h) - P_m(t+h)|_i$$

Donde:

$P_{f(t+h)}$, Es la potencia predicha en el instante "t" para la hora "t+h" ("h" puede variar entre 1 y 48)

$P_{m(t+h)}$, Es la potencia medida en el instante "t+h" ("h" puede variar entre 1 y 48)

N, Es el número de periodos de tiempos predichos. Los periodos de tiempo tienen un tamaño de 48 horas

A partir de la Ecuación 7.8 y Ecuación 7.9 se puede calcular el coste de desvío por unidad de energía producida, Ecuación 7.10.

Ecuación 7.10

$$Cd_e = \overline{Cd} \times \frac{NMAE}{100}$$

Donde:

Cd_e , Es el coste de desvío medio por unidad de energía generada por el aerogenerador (en Euros/MWh generados)

Como se observa en la Ecuación 7.10, el coste de desvío específico es función del error que se cometa en la predicción de la potencia eólica. En este documento se comparará el coste de desvío frente a los costes totales de producción de energía eléctrica de origen eólico en función del error de predicción.

Por otro lado, se hará una comparativa del coste de desvío específico, Cd_e , con relación al precio de venta de la energía eléctrica. Para el cálculo del precio de venta de la energía eléctrica se ha partido de la información de los precios horarios de venta del periodo 2007-2011 en el mercado español. Estos precios están publicados en la página web del operador del mercado eléctrico español [46].

Para estimar el precio medio específico, Pre (en €/MWh generado), se ha seguido un procedimiento similar al considerado para estimar el coste de desvío medio, \overline{Cd} .

La incorporación del coste de desvío, Cde , como un nuevo factor de coste de producción, afectará a la rentabilidad económica de los parques eólicos. El grado de afección dependerá del error en la predicción de la potencia eólica y del rendimiento energético del aerogenerador, Ecuación 7.11. Es por ello que los resultados se han particularizado según sea dicho rendimiento.

Ecuación 7.11

$$EP = \frac{\text{Energía eléctrica generada en un año por un aerogenerador}}{\text{Potencia nominal del aerogenerador}}$$

Donde:

EP, Es el rendimiento energético de un aerogenerador situado en un área eólica determinada (en MWh/MW)

7.3 Los Datos Meteorológicos Usados

Los datos meteorológicos utilizados se corresponden con los datos de velocidades medias horarias pertenecientes a seis estaciones meteorológicas (WS-1 a WS-6) (Figura 7. 1) y relativos al periodo 1999-2010. Las estaciones se encuentran ubicadas en seis de las siete islas del archipiélago canario; Lanzarote, Fuerteventura, Gran Canaria, Tenerife, La Palma y El Hierro.

Esta información fue proporcionada por la Agencia Española de Meteorología (AEMET) del ministerio de agricultura, alimentación y medioambiente del gobierno español.

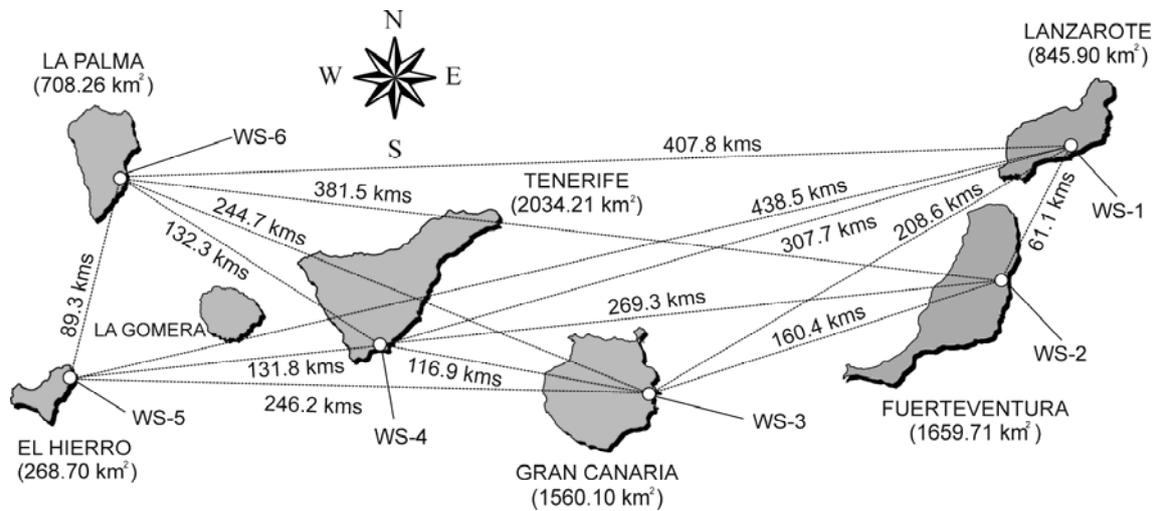


Figura 7.1: Localización de las estaciones meteorológicas usadas (Velázquez et al., 2011b).

La figura 7.1 Muestra los nombres de las Islas (Lanzarote, Fuerteventura, Gran Canaria, Tenerife, La Palma y El Hierro), sus áreas (in km²), las distancias entre las estaciones meteorológicas (en Km) y los códigos de referencias asignadas a cada estación (WS-1, WS-2, WS-3, WS-4, WS-5 y WS-6).

7.4 Cálculos y análisis de resultados

A partir de la información disponible para cada una de las estaciones meteorológicas y una vez calculado la potencia eólica media horaria mensual, $\overline{P_{h,m}}$ Ecuación 7.3, se han obtenido las distribuciones horarias medias de la potencia eólica para cada uno de los meses del año. Ecuación 7.12. Los resultados se muestran en la figura 2.

Ecuación 7.12

$$\overline{P_{h,m}(\%)} = \frac{\overline{P_{h,m}}}{\sum_{h=1}^{24} \overline{P_{h,m}}} \times 100$$

Donde:

$\overline{P_{h,m}(\%)}$; Es el valor relativo de $\overline{P_{h,m}}$

En la figura 7.2 se observa que el comportamiento eólico a lo largo del día para cada uno de los meses del año es similar. La aportación relativa, sobre el total del día, de la densidad de potencia eólica, Ecuación 7.12, entre las 21:00h y las 09:00h es poco variable. Es a partir de las 09:00h donde ésta comienza a crecer paulatinamente hasta conseguir el máximo entre las 13:00 y 16:00, según sea el mes del año.

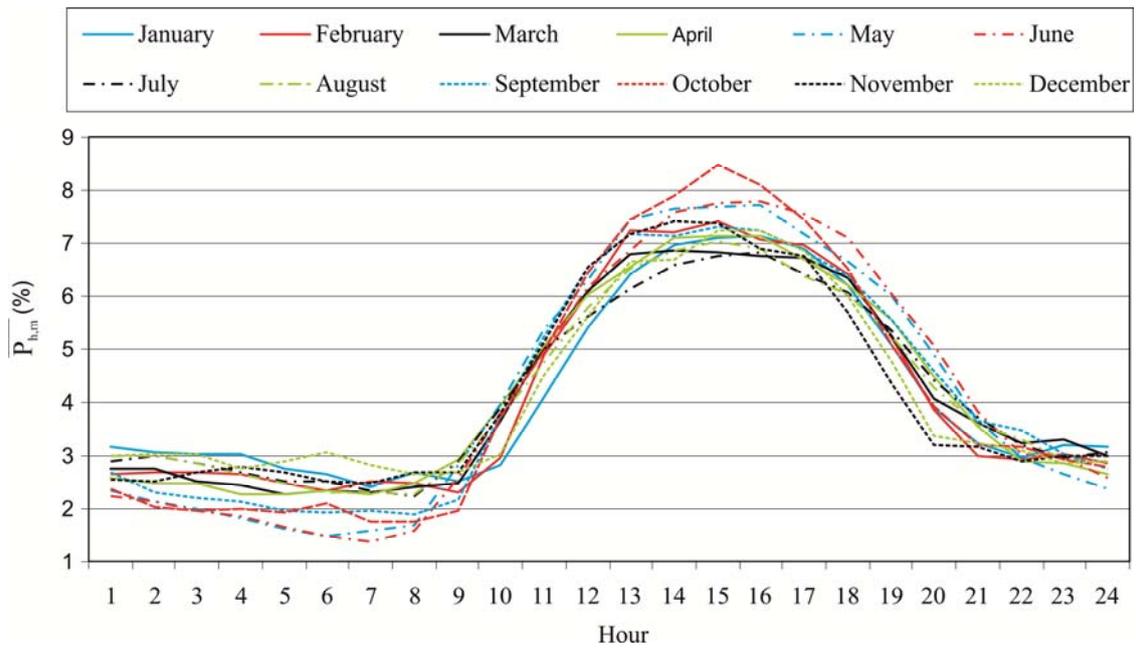


Figura 7.2: Distribuciones horarias medias porcentuales de la potencia eólica para cada uno de los meses del año.

A partir de la Ecuación 7.5 se calculan las densidades de potencias eólicas medias para cada uno de los meses del año, las cuales se muestran en la figura 7.3.

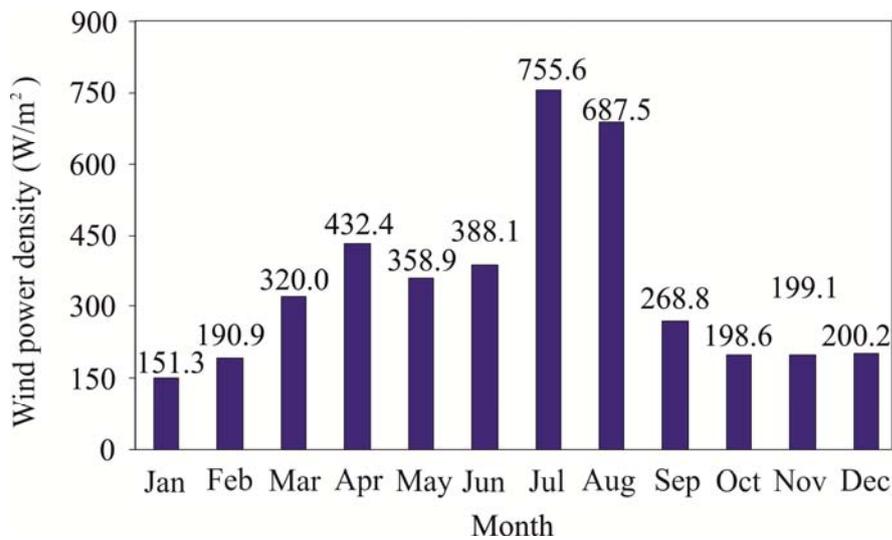


Figura 7.3: Distribución de la densidad de la potencia eólica media mensual

Se observa que la potencia media fluctúa en función de la estación del año. En invierno, el viento aliso característico del archipiélago canario origina bajas densidades de potencia eólica. Sin embargo, dicha densidad de potencia eólica se incrementa en primavera y alcanza los valores máximos en verano.

Para evaluar la contribución del potencial eólico de cada uno de los meses a la producción eólica total del año, se ha calculado los valores relativos a partir del parámetro energía eólica Ecuación 7.13. Dicho cálculo se ha basado en el parámetro de energía y no en el de potencia eólica, debido a que el número de horas totales para cada uno de los meses es diferente.

Ecuación 7.13

$$E_m(\%) = \frac{\overline{P}_m \times N_{h,m}}{\sum_{h=1}^{12} \overline{P}_m \times N_{h,m}} \times 100$$

Donde:

$E_m(\%)$, Es el valor relativo de la energía eólica mensual respecto a la total del año

$N_{h,m}$, Es el número de horas del mes "m"

\overline{P}_m , Es la densidad de potencia eólica media para el mes "m", Ecuación 7.5.

La figura 7.4 muestra la distribución relativa de la energía eólica mensual. Estos resultados serán los que representen las condiciones del aprovechamiento eólico del archipiélago canario.

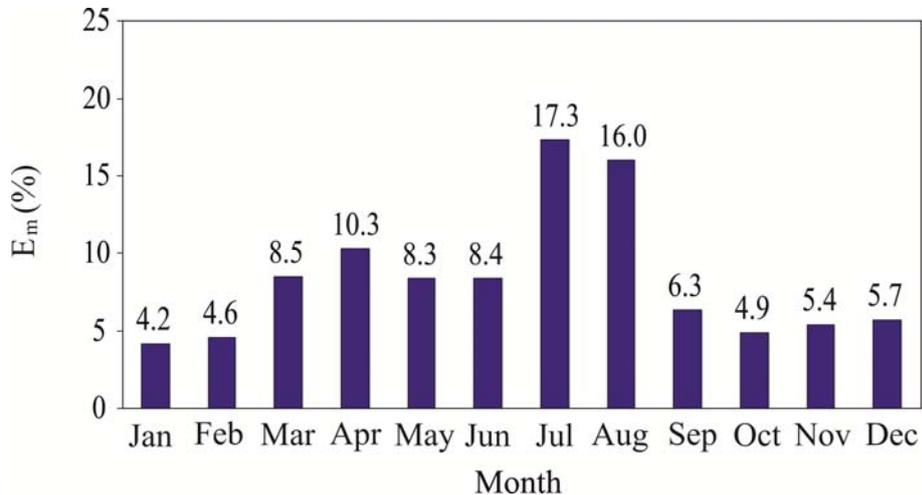


Figura 7.4: Distribución relativa porcentual de la energía eólica mensual.

En los resultados que se muestran en la figura 7.4 se observa que es en los meses de verano y fundamentalmente en los de julio y agosto donde se concentrará la mayor producción de energía por parte del aerogenerador. Concretamente en estos dos meses se concentra el 33,3% de la producción eólica total, cuando en términos temporales ambos

meses equivalen al $17\% \left(\frac{62 \text{ days}}{365 \text{ days}} \times 100 \right)$ del tiempo total del año. Por otro lado, en el otro extremo, se encuentran los meses de octubre a febrero, que siendo equivalentes al 41,4% del tiempo total del año, concentran únicamente el 24,8% de la producción eólica total.

7.4.1 Coste económico del desvío entre la potencia medida y la predicha.

A partir de la información publicada por el operador del sistema eléctrico español relativa a los costes de desvío y mediante la aplicación de la Ecuación 7.1, se ha estimado un coste medio horario para cada uno de los meses del año, Tabla 7.1.

Tabla 7.1: Coste medio horario, para cada mes, de la energía desviada (€/MWh).

Mes/Hora	1	2	3	4	5	6	7	8	9	10	11	12
Enero	16.7	12.9	13.3	13.6	13.8	13.5	16.0	15.7	14.5	13.3	14.0	12.7
Febrero	13.5	10.2	10.3	10.1	9.9	9.5	9.3	11.6	10.7	10.9	10.8	12.4
Marzo	12.8	10.4	10.0	10.7	10.4	10.5	12.1	14.0	10.6	11.0	12.4	11.1
Abril	12.7	11.3	9.3	9.3	9.1	8.9	9.8	11.4	12.3	11.5	11.2	9.3
Mayo	9.6	9.4	9.1	9.7	9.7	8.8	8.3	8.8	9.3	9.4	10.4	10.4
Junio	8.6	7.7	7.5	8.4	8.4	8.0	8.0	10.2	9.8	8.8	10.3	9.4
Julio	11.6	8.5	7.3	7.8	7.3	6.5	6.2	10.9	10.4	7.7	10.3	9.2
Agosto	9.8	7.2	7.1	7.2	7.0	6.1	6.9	9.1	10.0	8.5	10.1	9.0
Septiembre	11.8	8.7	8.9	9.2	7.9	8.1	7.4	9.5	11.9	9.9	12.3	14.0
Octubre	14.9	12.2	11.1	11.4	10.7	10.7	11.7	12.5	11.1	12.2	12.8	12.9
Noviembre	13.9	10.6	11.6	11.6	11.6	10.7	9.9	11.8	10.7	11.1	11.7	10.8
Diciembre	18.2	14.9	14.4	15.6	15.0	15.3	14.2	13.6	13.8	12.9	13.6	13.1

Mes/Hora	13	14	15	16	17	18	19	20	21	22	23	24
Enero	13.8	12.6	13.3	12.2	11.4	14.1	22.0	22.8	21.5	25.2	19.9	16.9
Febrero	13.9	12.4	13.6	11.8	11.1	13.1	18.4	22.7	23.9	23.3	16.7	15.4
Marzo	12.7	11.3	12.0	11.0	10.6	12.1	15.7	20.6	18.9	19.3	15.7	15.6
Abril	9.5	10.7	9.9	12.1	10.0	9.6	9.5	10.2	16.3	14.9	14.4	13.5
Mayo	11.0	10.9	9.6	10.4	9.0	9.3	8.8	8.8	12.0	12.8	11.8	11.0
Junio	10.6	10.3	8.3	10.2	9.7	10.3	9.1	9.0	9.5	11.5	10.4	9.7
Julio	11.5	11.5	9.1	10.8	10.7	10.8	10.0	10.6	9.4	9.2	10.4	11.6
Agosto	10.3	10.0	9.6	10.6	10.9	11.7	11.1	10.8	9.9	12.3	11.8	10.3
Septiembre	13.0	13.0	11.8	13.3	11.9	11.8	11.5	11.6	15.4	16.0	15.6	14.3
Octubre	13.5	12.4	12.2	14.2	12.9	13.1	13.2	16.9	19.3	18.2	19.2	18.7
Noviembre	12.0	11.2	12.2	10.9	14.0	17.4	17.9	22.3	20.2	21.2	17.2	15.8
Diciembre	14.3	13.1	14.5	13.0	12.0	15.2	20.9	23.6	22.3	28.7	22.6	19.8

En la tabla 7.1 se observa que el coste económico por unidad de energía desviada varía dependiendo de la hora del día. En el estudio realizado de las características del recurso eólico del archipiélago canario, se muestra que la distribución del aprovechamiento de la energía eólica y, por lo tanto, de la producción eléctrica por un aerogenerador, depende de la hora del día (figura 7.2). Por lo tanto, si se considera constante a lo largo del año el error que se comete en la predicción horaria de la potencia eléctrica generada por un aerogenerador, el coste de desvío total para cada hora será diferente. Ello, es consecuencia de la variación horaria del coste de desvío unitario (tabla 7.1) y de la cuantía de la energía total desviada cada hora.

Estos aspectos han sido considerados para el cálculo del coste de desvío medio mensual, Ecuación 7.4. Los resultados obtenidos se muestran en la figura 7.5.

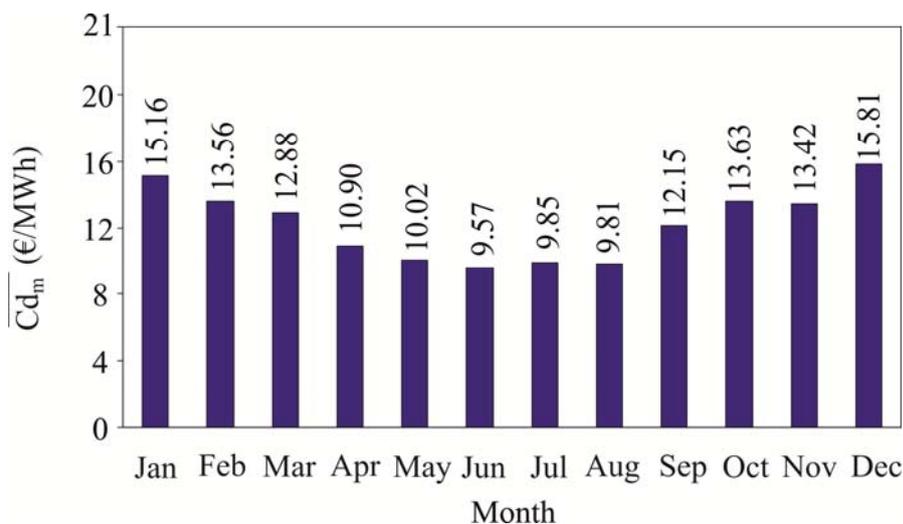


Figura 7.5: Coste medio mensual de la energía desviada.

A partir de los resultados obtenidos del aprovechamiento relativo de la energía eólica (Figura 7.4) y del coste de desvío medio mensual (Figura 7.5), se ha calculado el valor medio anual para el coste de desvío por cada unidad de energía desviada, Ecuación 7.7. Dicho coste, para el periodo de estudio considerado, es de 11,46 €/MWh desviado.

7.4.2 Estructura de coste de la energía generada por un aerogenerador

Si a la estructura típica de costes de producción utilizada en la literatura científica [40-45] se le incorpora el factor de costes analizado en este documento, el coste total de la energía eléctrica producida por una turbina eólica puede ser calculado mediante la Ecuación 7.14

$$\text{Ecuación 7.14} \quad C_T = C_I + C_{O\&M} + C_d$$

Donde:

C_T , Es el coste total de la energía eléctrica generada por un aerogenerador (en Euros/MW)

C_I , Es el coste de la inversión inicial (en Euros/MW)

$C_{O\&M}$, Es el coste de operación y mantenimiento (en Euros/MW)

C_d , Es el coste total debido al desvío entre la potencia eléctrica predicha y la medida (en Euros/MW)

En este documento un modelo de cálculo simplificado del coste de energía específico (COE) fue elegido, Ecuación 7.15. Este método, similar al método EPRI TAG [41,43,45] estima la relación de coste entre el coste total y la energía eléctrica anual producida por el aerogenerador.

El coste de la inversión inicial puede estimarse en 1.200.000€/MW [3,10,47] y el coste de operación y mantenimiento en 45.000€/MW [3]. Teniendo en cuenta estos valores de costes, la expresión del rendimiento energético, Ecuación 7.11 y la expresión del coste de desvío específico, Ecuación 7.10, el coste específico de la energía eléctrica generada por un aerogenerador puede expresarse según la Ecuación 7.15.

$$\text{Ecuación 7.15} \quad COE = \frac{C_I \times FCR}{EP} + \frac{C_{O\&M}}{EP} + C_{d_e}$$

Donde:

COE, Es el coste específico de la energía eléctrica generada por un aerogenerador (en Euros/MWh)

FCR, es la tasa de cargo fijo por año y su valor en este trabajo es de 0,05. En ella, se supone que el período de la deuda es igual a la vida útil del aerogenerador.

En este estudio, el periodo de vida de trabajo se tomó como 20 años, una longitud de tiempo que normalmente está cubierto por la garantía de los fabricantes.

7.4.3 Precio de la Energía Eléctrica

En la tabla 7.2 se muestra la evolución del precio medio de venta de la energía eléctrica en el mercado libre español para los años 2009-2011. Los datos que se reflejan han sido calculados como la media aritmética de los valores del precio de venta horario de la energía eléctrica.

Tabla 7.2: Evolución del precio medio aritmético de la energía eléctrica en el mercado libre español.

Año	Precio medio de la energía eléctrica (€/MWh)
2009	40.30
2010	45.00
2011	59.14

Para el análisis objeto de este documento se han considerado los datos horarios relativos al último año (año 2011).

Los precios medios aritméticos de la tabla 7.2 no tienen en cuenta el régimen específico de aprovechamiento de la energía eólica y por lo tanto de generación de energía eléctrica por un aerogenerador (figuras 7.2 y 7.4). En este documento, para el cálculo del precio de venta medio, se ha partido de los datos horarios disponibles en la web de la OMEL [46] y se ha seguido un procedimiento similar al considerado para calcular el coste de desvío, \overline{Cd} .

En primer lugar se ha calculado el precio medio horario para cada uno de los meses del año, Ecuación 7.16.

Ecuación 7.16

$$\overline{\text{Pr}}_{h,m} = \frac{1}{N_d} \sum_{d=1}^{N_d} \text{Pr}_{h,m,d}$$

Donde:

$\overline{\text{Pr}}_{h,m}$, Es el precio de venta medio para la hora "h" del mes "m" (en Euros/MWh)

$\text{Pr}_{h,m,d}$, Es el precio de venta para la hora "h" del día "d" y relativo al mes "m" (en Euros/MWh)

N_d , Es el número de días del mes considerado.

En segundo lugar, teniendo en cuenta que el régimen de aprovechamiento horario de la energía eólica a lo largo del día es variable (figura 7.2), se ha estimado, para cada uno de los meses, un precio medio de venta de la energía eléctrica, Ecuación 7.17. Los resultados obtenidos se muestran en la figura 6.

Ecuación 7.17

$$\overline{\text{Pr}}_m = \frac{1}{\sum_{h=1}^{24} \overline{\text{P}}_{h,m}} \sum_{h=1}^{24} \overline{\text{Pr}}_{h,m} \times \overline{\text{P}}_{h,m}$$

Donde:

$\overline{\text{Pr}}_m$, Es el precio medio de venta de la energía eléctrica para el mes "m" (en Euros/MWh)

$\overline{\text{P}}_{h,m}$, Es la densidad de potencia eólica media para la hora "h" del mes "m" (en W/m²),

Ecuación 7.3

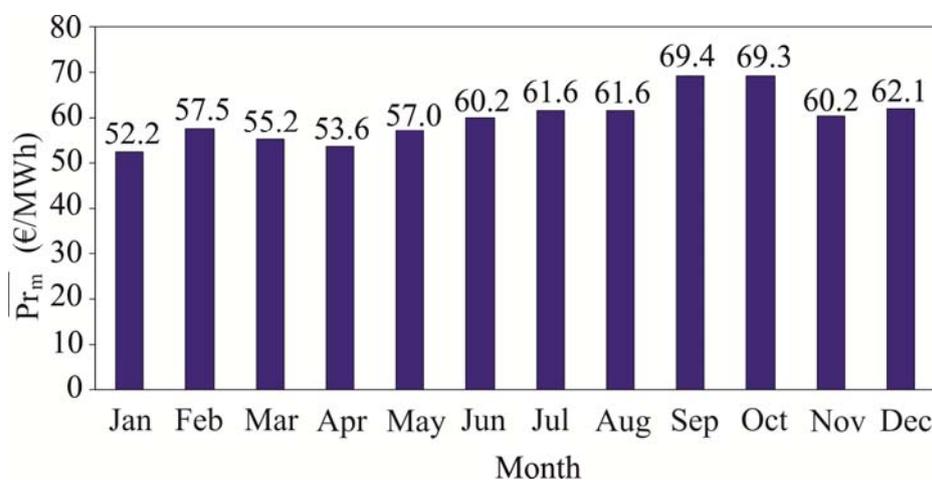


Figura 7.6: Precios de venta medios mensuales de la energía eléctrica (€/MWh).

Por último, teniendo en cuenta la distribución del aprovechamiento mensual de la energía eólica (figura 7.4), se ha estimado el precio medio específico de venta de la energía eléctrica (Pre), Ecuación 7.18, el cual ha sido de 59.98€/MWh.

Ecuación 7.18

$$Pr_e = \frac{1}{\sum_{h=1}^{12} E_m} \sum_{h=1}^{12} Pr_m \times E_m$$

Donde:

Pr_e , Es el precio medio específico de venta de la energía eléctrica (en Euros/MWh)

E_m , Es la densidad de energía eólica para el mes "m", Ecuación 7.6

7.4.4 Análisis de resultados

El coste específico de producción de la energía eléctrica por un aerogenerador es función del rendimiento energético de la misma (Ecuación 7.15). Se observa que cuanto mayor sea el rendimiento de la energía (EP), menor será el coste debido a la inversión inicial y el coste de operación y mantenimiento. Por ello, los resultados se han particularizado según sea el rendimiento energético del aerogenerador.

En España, la evolución del rendimiento energético medio en los últimos 5 años ha variado entre 2000 y 2200 MWh/MW. En el caso particular de Canarias dicha variación se encuentra en el rango comprendido entre 2.200 y 2.600 MWh/MW (OMEL). Las expectativas para el rendimiento energético medio de los parques eólicos a instalar en España, con el horizonte del año 2020, es que éste disminuya hasta valores incluso inferiores a 2.000 MWh/MW [3].

Por este motivo los resultados se han analizado para un rango del rendimiento energético (EP) igual a: $1.800 \leq EP \leq 2.800$.

Por otro lado, dentro de la estructura de costes de producción de la energía eléctrica generada por un aerogenerador (Ecuación 7.15), también se encuentra el término relativo al coste de desvío específico, Cde. Este factor de coste es inferior al 61% con una probabilidad del

97,5%. Por este motivo se han analizado los resultados en base a un rango de errores de predicción del 0% al 60%.

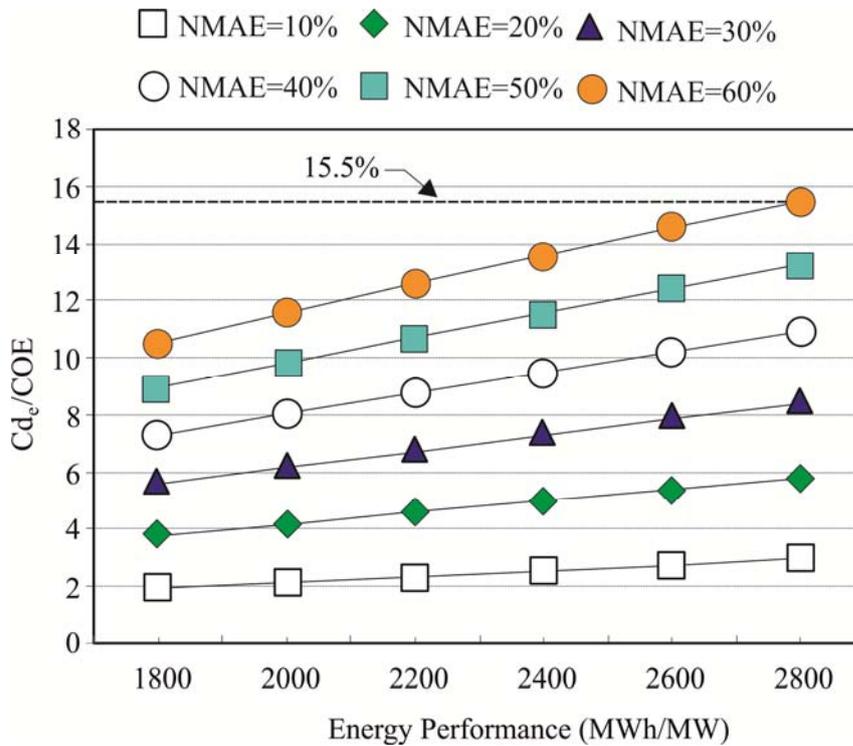


Figura 7.7: Contribución del coste de desvío al coste de producción de la energía eléctrica por un aerogenerador.

En la figura 7.7 se muestran los resultados de la contribución del coste de desvío al coste total de producción de la energía eléctrica generada por una aerogenerador en función del error en la predicción (NMAE). Se observa que la contribución del coste de desvío será tanto mayor cuanto mayor sea el error. Dicha contribución puede llegar a ser de hasta el 15,5%, para el caso de un error del 60% y un rendimiento energético de 2.800 MWh/MW.

En la figura 7.8 se comparan los costes totales de producción (COE) con el precio de venta de la energía eléctrica (Pre), Ecuación 7.18.

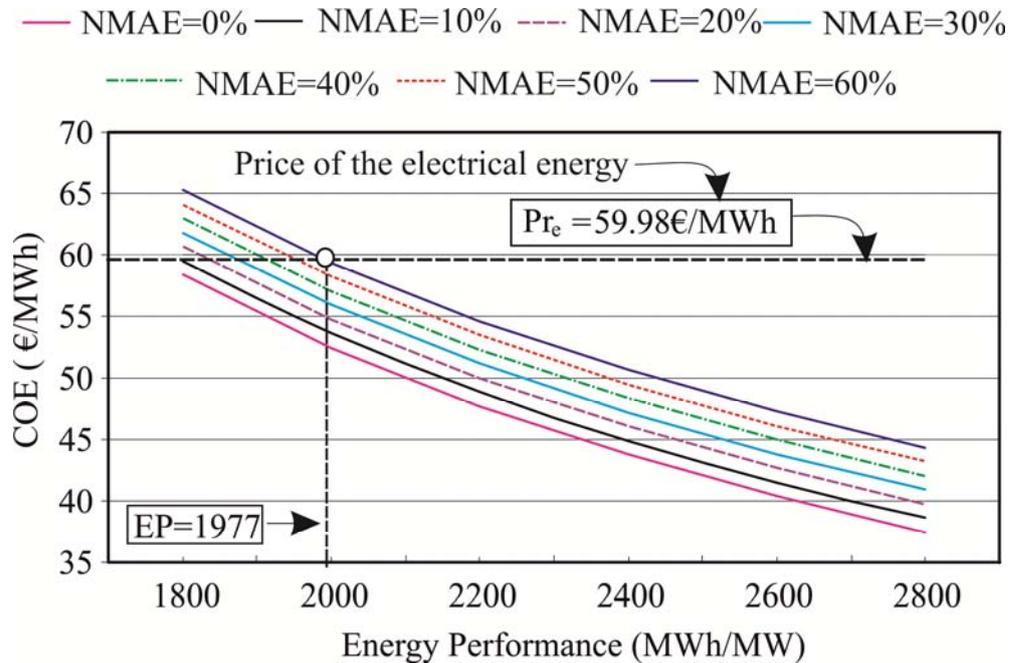


Figura 7.8: Coste total de producción de la energía eléctrica generada por un aerogenerador (COE).

Puede observarse en la figura 7.8 que, para el caso particular donde no hay errores en la predicción (NMAE=0%), el rendimiento energético requerido a un emplazamiento para que el coste total de producción sea igual al precio de venta de la energía, es inferior a 1.800 MWh/MWh. Sin embargo, si el error de predicción es igual al 60%, el rendimiento energético que debería tener el emplazamiento para que el coste de generación sea inferior a Pr_e , ha de ser superior a 1.977 MWh/MW. Por tanto, de la observación de la figura 8 puede concluirse que el rendimiento energético exigido a un emplazamiento para que el coste de producción no sea superior al precio de venta de la energía, será tanto mayor cuanto más elevado sea el error en la predicción.

En la figura 7.9 se muestra la relación que existe entre el coste específico de desvío (Cde) y el precio medio específico de la energía eléctrica (Pr_e). Este análisis se ha llevado a cabo en función del error del modelo de predicción (NMAE).

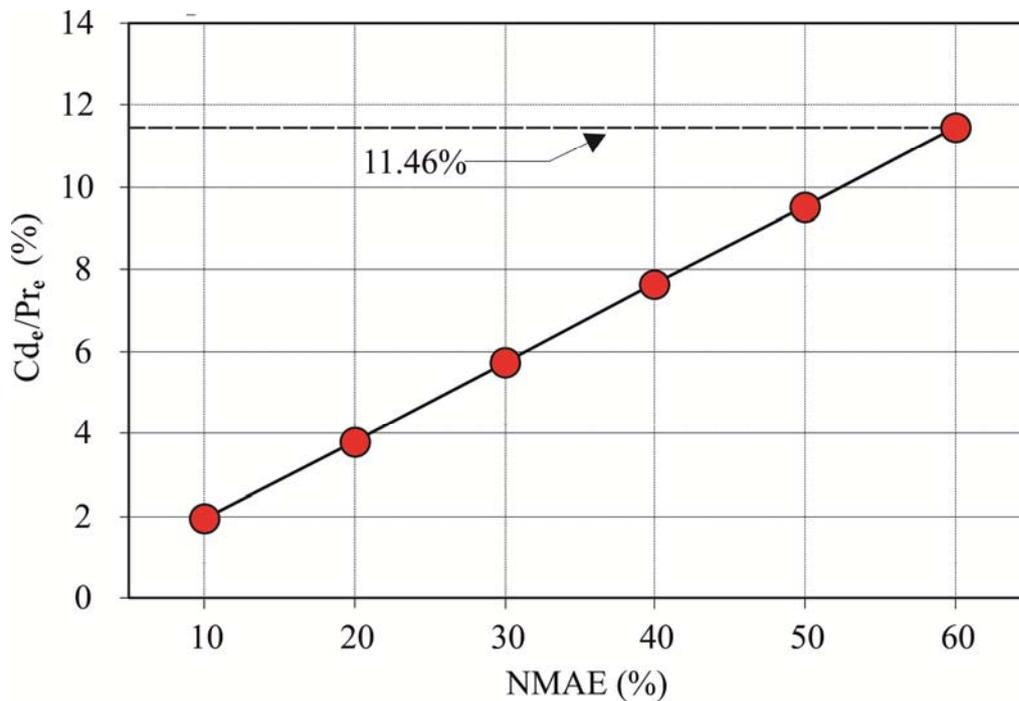


Figura 7.9: Relación existente entre el coste de desvío específico (Cde) y los ingresos por Mwh (Pre)

De la observación de la figura 7.9 se deduce que el coste de desvío específico (Cde) puede suponer un 11,46% de los ingresos. Es decir, del valor del precio específico de venta de la energía eléctrica (Pre).

El ingreso económico total de un aerogenerador, localizado en un área específica, por la venta de energía, puede expresarse según la Ecuación (7.19).

Ecuación 7.19

$$INC = P \times EP \times Pr_e$$

Donde:

P, Es la potencia eléctrica instalada en el granja eólica (en MW)

INC, Son los ingresos totales relativos a la venta de la energía eléctrica generada por la granja eólica (en Euros)

El coste económico del desvío, Ecuación 7.10, se puede incorporar en la Ecuación 7.19, teniendo en cuenta los resultados reflejados en la figura 7.9, como una pérdida de ingresos equivalentes. De esta forma, la Ecuación 7.19 se transforma en la expresión recogida en la Ecuación 7.20.

$$\text{Ecuación 7.20} \quad \text{INC} = P \times EP \times Pr_e \left(1 - \frac{Cd_e}{Pr_e} \right)$$

En la Ecuación 7.21 se define el rendimiento de la energía normalizada (NEP). El NEP es el rendimiento energético de un aerogenerador en un área específica, teniendo en cuenta la pérdida energética equivalente al coste económico derivado del error en la predicción de la potencia eólica.

$$\text{Ecuación 7.21} \quad \text{NEP} = EP \times \left(1 - \frac{Cd_e}{Pr_e} \right)$$

Donde:

NEP; Es el rendimiento energético normalizado (en MWh/MW)

Por lo tanto, si se incorpora el coste económico del desvío a los ingresos, como alternativa a su incorporación a la estructura de costes, éstos deberían expresarse según la Ecuación (7.22).

$$\text{Ecuación 7.22} \quad \text{INC} = P \times \text{NEP} \times Pr_e$$

En la figura 7.10 se muestran los resultados obtenidos para los NEP's en función de los valores del eficiencia energética (EP) considerados y del error en la predicción de la potencia eólica (NMAE).

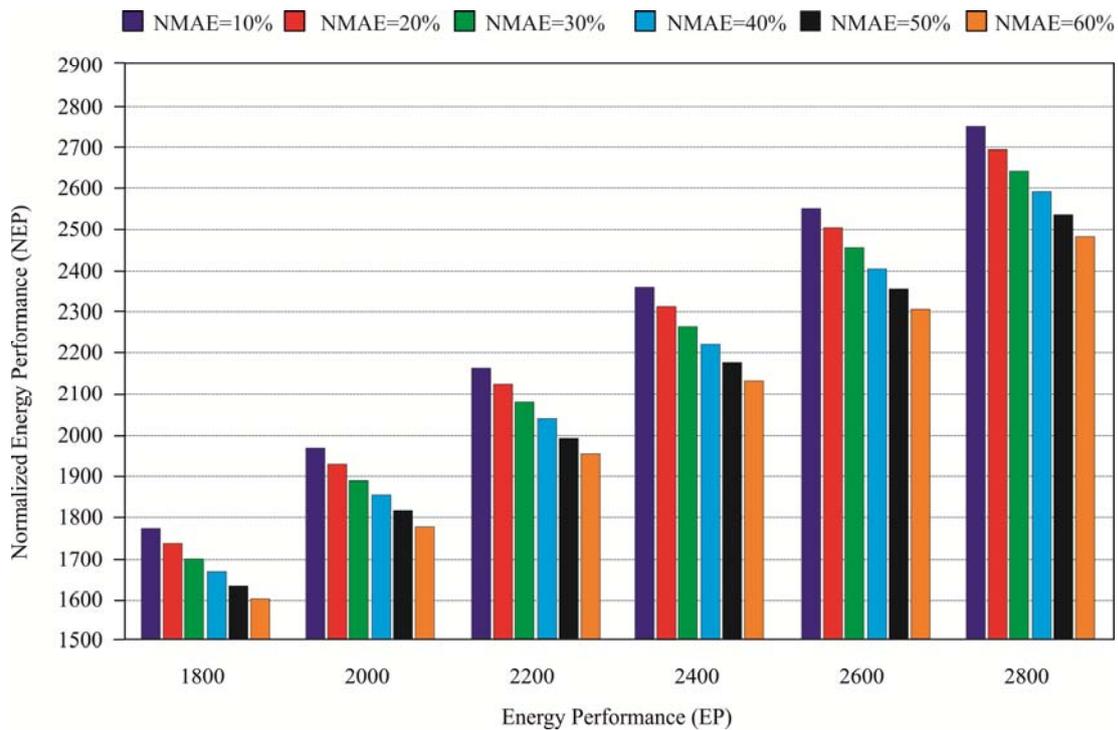


Figura 7.10: Variación del rendimiento de la energía normalizada en función del valor del NMAE.

Se observa en la figura 7.10 que, áreas con una eficiencia energética inicial (NMAE=0%) de 1.800 MWh/MW pueden llegar a tener, para un error de predicción del 60% (NMAE=60%), un NEP de 1.594 MWh/MW. Este NEP equivale a una pérdida energética de 206 MWh/MW debido al coste económico del desvío en la predicción. Por otro lado, áreas con un energy performance inicial de 2.800, tienen un NEP, para errores del 60% (NMAE=60%), de 2.479 MWh/MW. Es decir, una pérdida energética equivalente de 321MWh/MW.

Teniendo en cuenta que para rentabilizar económicamente un parque es necesario que ésta tenga, en el emplazamiento en cuestión, un rendimiento energético mínimo, habrá de tenerse en consideración estas pérdidas energéticas equivalentes en la planificación de las zonas de interés para la instalación de parques eólicos. Emplazamiento que inicialmente, sin la consideración de los costes de desvío, pudieren ser rentables económicamente, podrían perder dicha condición al considerar los mismos. En general, los costes de los desvíos en la predicción eólica disminuirán la rentabilidad económica de los parques.

7.5 Los sistemas de hidrobombeo reversibles como medio para la gestión de los excedentes o déficits de energía eléctrica de origen eólica

En los últimos tiempos, en muchos sistemas eléctricos débiles insulares se han implementado sistemas de hidrobombeo reversible con almacenamiento energético (siglas en inglés, PHSS) con el objetivo de optimizar la integración de sistemas de generación de energía no gestionables como es la eólica.

Estos sistemas bien podrían estar gestionados directamente por el operador del sistema o bien asociados a parques eólico de promotores particulares.

En el primero de los casos serviría para una gestión integral de la red, y por lo tanto de todas las instalaciones eólicas conectadas a la misma. En este sentido, el PHSS podría bombear y acumular energía en horas valle y contribuir con la energía almacenada en horas punta. Se conseguiría con ello una mayor y mejor integración de la energía eólica en los sistemas eléctricos débiles insulares así como se podría plantear una política de reducción de los costes de desvío para este tipo de instalaciones o bien permitir, sin penalización, un margen de error mayor en la predicción.

En el segundo de los casos, cuando el PHSS está asociado a un parque eólico concreto, es el propio promotor del mismo el que gestionaría los excedentes/déficits en relación con su predicción para bombear/turbinar agua y por lo tanto minimizar los costes de desvíos. Es decir, en el caso de que la generación real sea superior a la prevista, se acumularía el excedente (potencia real- potencia prevista) en el PHSS para así evitar penalizaciones. Idem en el caso contrario.

7.6 Conclusiones

Los desvíos entre los valores predichos de la producción de energía eléctrica y los reales medidos, para una demanda de energía establecida, provocan alteraciones al sistema eléctrico cuya solución supone un coste económico adicional al mismo. Este coste económico es imputado proporcionalmente a las fuente de generación que provocan el desvío.

El error en la predicción de la potencia eléctrica generada por un aerogenerador puede llegar a ser hasta del 61%, siendo en general inferior a este valor con una probabilidad del 97,5% (AEE,2006; ANEMOS; IDAE, 2007; Risø DTU, 2011).

En este documento se propone que el coste económico específico imputado al aerogenerador debido a la desviación en la predicción (Cde), sea considerado como un factor adicional en la estructura de coste de producción de la energía eléctrica por un parque eólico, Ecuación 7.15. Su contribución al coste total depende del error en la predicción, pudiendo llegar a ser del 15,5% para un error de predicción (NMAE) del 60%.

En el análisis económico del proyecto de un parque eólico, es condición necesaria que el coste de producción total de la energía eléctrica (COE) sea inferior al precio de venta específico de la misma (Pre). Es decir, a los ingresos por unidad de energía. El rendimiento energético exigido a un parque eólico en un área específica para que su coste de producción sea inferior al precio de venta depende del error en la predicción de la potencia eléctrica. Para errores de predicción del 0% dicho rendimiento es inferior a 1.800MWh/MW. Cuando el error aumenta hasta el 60%, éste pasa a ser de 1.977 MWh/MW.

Si de forma alternativa se considerara el coste económico debido al desvío como una pérdida energética equivalente del parque eólico, ésta podría llegar a ser hasta de 321 MWh/MW para un error en la predicción (NMAE) del 60%. Es decir, emplazamientos que inicialmente, sin la consideración de los costes de desvíos, pudieran ser rentables económicamente, podrían perder dicha condición al considerarse los mismos. En general, el coste económico asociado a los desvíos en la predicción eólica disminuirá la rentabilidad económica de los parques eólicos. El coste de desvío específico, Ecuación 7.10, puede llegar a ser equivalente a una disminución del 11,46% de los ingresos de un parque eólico.

Por lo tanto, estas pérdidas energéticas equivalentes deberán tenerse en consideración en la planificación de las zonas de interés para la instalación de parques eólicos.

7.7 REFERENCIAS

- [1] Parlamento Europeo y del Consejo, 2009. Directive 2009/28/EC of 23 April 2009 on the promotion of the use of energy from renewable sources. Boletín Oficial de la Unión Europea: pp L140/16 – L140/62
- [2] Gobierno de las islas Canarias, 2005. Plan Energético de Canarias 2006-2015 (PECAN 2006-2015). Consejería de Empleo, Industria y Comercio del Gobierno de Canarias, 2005.
- [3] IDAE, 2011. Plan de Energías Renovables 2011-2020. . Instituto para la Diversificación y Ahorro de Energía
- [4] Operador del sistema eléctrico español , 2011. El sistema eléctrico español. www.ree.es
- [5] Bilgili M., Sahin B., Abdulkadir, 2007. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. *Renewable Energy*;32:2350–2360.
- [6] Carta J.A., Velázquez S., 2011. A new probabilistic method to estimate the long-term wind speed characteristics at a potential wind energy conversion site. *Energy*; 36. pp 2671-2685
- [7] Oztopal A., 2006. Artificial Neural Network approach to spatial estimation of wind velocity. *Energy Conversion and Management*;47:395–406.
- [8] Rogers A, Rogers J., Manwell J., 2005. Comparison of the performance of four Measure-Correlate-Predict algorithms. *Journal of Wind Engineering and Industrial Aerodynamics*;93:243–64.
- [9] Velázquez S., Carta J.A., Matías J.M., 2011. Influence of the input layer signals of ANNs on wind power estimation for a target site: a case study. *Renewable and Sustainable Energy Reviews*;15:1556-1566.
- [10] Velázquez S., Carta J.A., Matías J.M., 2011. Comparison between ANNs and linear MCP algorithms in the long-term estimation of the cost per kW h produced by a wind turbine at a candidate site: A case study in the Canary Islands. *Applied Energy*; 88. pp 3869–3881
- [11] Carolin Mabel M., Fernandez E, 2008. Analysis of wind power generation and prediction using ANN:A case study. *Renewable Energy* 33: pp 986–992
- [12] Costa A., Crespo A., Navarro J., Lizcano G., Madsen H., Feitosa E., 2008. A review on the young history of the wind power short-term prediction. *Renewable and Sustainable Energy Reviews*,12: pp 1725–1744
- [13] Landberg L., Giebel G., Aalborg H., Madsen H., Nielsen T., 2003a. Short-term Prediction-An Overview. *Wind Energy*, 6: pp 273–280
- [14] Lei M., Shiyan L., Chuanwen J., Hongling L., Yan Z., 2009. A review on the forecasting of wind speed and generated power. *Renewable and Sustainable Energy Reviews*, 13: pp 915–920
- [15] Ramírez-Rosado I., Fernández-Jiménez A., Monteiro C., Sousa J., Bessa R., 2009. Comparison of two new short-term wind-power forecasting systems. *Renewable Energy* 34: pp 1848–1854
- [16] Sánchez I., 2006. Short-term prediction of wind energy production. *International Journal of Forecasting*, 22: pp 43– 56

Capítulo 7: Influencia de la fiabilidad en la predicción a corto plazo de la potencia eléctrica producida por un parque eólico, en el coste de generación por MWh y en la planificación de las áreas eólicas. Un caso de estudio en las islas Canarias.

- [17] Gobierno de España, 1997. Real Decreto 2019/1997, de 26 de diciembre, por el que se organiza y regula el mercado de producción de energía eléctrica. Boletín Oficial del Estado Español, 310: pp 38047-38057 (en español)
- [18] Gobierno de España, 2006. Real Decreto-Ley 3/2006, de 24 de febrero, por el que se modifica el mecanismo de casación de las ofertas de venta y adquisición de energía presentadas simultáneamente al mercado diario e intradiario de producción por sujetos del sector eléctrico pertenecientes al mismo grupo empresarial. Boletín Oficial del Estado Español, 50: pp 8015-8016 (en español)
- [19] Gobierno de España, 2006. CORRECCIÓN de errores del Real Decreto-ley 3/2006, de 24 de febrero, por el que se modifica el mecanismo de casación de las ofertas de venta y adquisición de energía presentadas simultáneamente al mercado diario e intradiario de producción por sujetos del sector eléctrico pertenecientes al mismo grupo empresarial. Boletín Oficial del Estado Español, 53: pp 8659-8659 (en español)
- [20] Gobierno de España, 2006. Resolución de 24 de mayo de 2006, de la Secretaría General de Energía, por la que se aprueban las Reglas de funcionamiento del mercado diario e intradiario de producción de energía eléctrica. Boletín Oficial del Estado Español, 128: pp 20155-20192 (en español)
- [21] Parlamento Europeo y del Consejo, 2003. Directive 2003/54/EC of 26 June 2003 concerning common rules for the internal market in electricity. Official Journal of the European Union: pp L176/37 – L176/55
- [22] Calero R., Carta J.A., 2004. Action plan for wind energy development in the Canary Islands. Energy Policy, 32: pp 1185-1197
- [23] Baker R, Walker SN, Wade JE, 1990. Annual and seasonal variations in mean wind speed and wind turbine energy production. Solar Energy; 45:285-9.
- [24] Burton T., Sharpe D., Jenkins N., Bossanyi E., 2011. Wind energy handbook. Second edition. John Wiley & Sons.
- [25] Hiester TR, Pennell WT, 1981. The siting handbook for large wind energy systems. 1st ed. New York: WindBook.
- [26] Justus CG, Mani K, Mikhail AS, 1979. Interannual and month-to-month variations of wind speed. Journal of Applied Meteorology; 18:913–20.
- [27] Klink K., 2002. Trends and interannual variability of wind speed distributions in Minnesota. J. Clim; 15: 3311-7.
- [28] Koepl GW, 1982. Putnam's power from the wind. Second ed. New York: Van Nostrand Reinhold Company.
- [29] Landberg L., Myllerup L., Rathmann O., Petersen E., Jørgensen B., Gylling N., Badger J., 2003b. Wind resource estimation—An overview. Wind Energy; 6:261-71.
- [30] ANEMOS.
http://www.anemosplus.eu/index.php?option=com_content&view=article&id=91&Itemid=69
- [31] IDAE, 2007. ANEMOS estudio sobre predicción eólica en la Unión Europea. Instituto para la Diversificación y Ahorro de Energía(Spanish initials, IDAE). (en español)

- [32] Risø DTU, 2011. The State of the Art in Short-Term Prediction of Wind Power. A Literature Overview, 2nd Edition. Risø DTU, Wind Energy Division.
- [33] AEE, 2006. Ejercicio de predicción. Asociación Española de la energía eólica (AEE). (en español)
- [34] Bergek A., Jacobsson S., 2010. Are tradable green certificates a cost-efficient policy driving technical change or a rent-generating machine?. Lessons from Sweden 2003–2008. Energy policy, 38: pp 1255-1271
- [35] Hasche B., Barth R., Swider D.J., 2007. Effects of improved wind forecasts on operational costs in the German electricity system.
- [36] Jenner S., Groba F., Indvik J., 2013. Assessing the strength and effectiveness of renewable electricity feed-in tariffs in European Union countries. Energy Policy, 52: pp 385-401
- [37] Jónsson T., Pinson P., Madsen H., 2010. On the market impact of wind energy forecasts. Energy Economics, 32: pp 313–320
- [38] Pinson P., Chevallier C., Kariniotakis G.N., 2007. Trading Wind Generation From Short-Term Probabilistic Forecasts of Wind Power. IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 22, NO. 3: pp 1148-1156
- [39] Ummels B.C., Gibescu M., Kling W.L., Paap G.C., 2006. Integration of Wind Power in the Liberalized Dutch Electricity Market. Wind Energy, 9: pp 579–590
- [40] Hau E., 2005. Wind turbines. 2nd ed. New York: Springer.
- [41] Manwell J.F., McGowan J.G., Rogers A.L., 2009. Wind energy explained. 2nd ed. Great Britain: John Wiley & Sons.
- [42] March F., Dlott E.H., Korn D.H., Madio F.R., McArthur R.C., Vachon W.A., 1982. Wind power for the electric-utility industry. 1st ed. Massachusetts: LexingtonBooks.
- [43] Nelson V., 2009. Wind energy. 1st ed. FL: CRC Press
- [44] Sherman J.M., Gresham M.S., Ferguson D.L., 1983. Wind systems life cycle cost analysis. 1st ed. New York: WindBooks.
- [45] Spera D.A., 1994. Wind turbine technology. New York: ASME Press.
- [46] Operador del Mercado Eléctrico Español. www.omel.es
- [47] EWEA, 2011. Wind energy targets for 2020 and 2030. European Wind Energy Association (EWEA).

CAPITULO 8

Desarrollo de un Modelo Dinámico de curva de potencia de un parque eólico utilizando las Redes Neuronales Artificiales. Aplicación a dos parques eólicos de Canarias.

INDICE

8.1 Introducción.....	254
8.2 Objetivo.....	254
8.3 Metodología.....	255
8.4 Datos de partida utilizados en el estudio.....	261
8.5 Arquitectura de las Redes Neuronales utilizadas.....	267
8.6 Discusión de los datos obtenidos.....	268
8.7 Conclusiones al capítulo.....	274
8.7 Referencias.....	276

ÍNDICE DE FIGURAS

Figura 8.1: Fases de los procesos de estimación de las velocidades y direcciones del viento

Figura 8.2: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se utiliza únicamente en la capa de entrada la Velocidad y Dirección del viento de la estación de referencia del parque

Figura 8.3: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se incorpora, adicionalmente, los datos de velocidad y dirección de una estación ajena al parque eólico

Figura 8.4: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando en la capa de entrada se utiliza exclusivamente la información de velocidad y dirección del viento de una estación ajena al parque eólico

Figura 8.5: Distribución en planta del parque eólico WF-1 en Gran Canaria

Figura 8.6: Curva de funcionamiento del aerogenerador GAMESA G47/660kW

Figura 8.7: Ubicación del parque eólico WF-2 en Lanzarote

Figura 8.8: Curva de funcionamiento del aerogenerador GAMESA G52/850kW

Figura 8.9: Ubicación de las estaciones anemométricas (WS) y parques eólicos (WF) utilizados en el estudio

Figura 8.10: Rosas de los vientos de las estaciones de referencia de los parques eólicos WF-1 y WF-2, respectivamente

Figura 8.11: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-1

Figura 8.12: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-1

Figura 8.13: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-2

Figura 8.14: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-2

Figura 8.15: Resultados del IoA para la hipótesis 2. Casos particulares de los parques eólicos WF-1 y WF-2

Figura 8.16: Grado de similitud en la precisión de los modelos dinámicos calculados según las hipótesis 1 y 3

ÍNDICE DE TABLAS

Tabla 8.1: Estaciones meteorológicas utilizadas en el estudio

Tabla 8.2: Parques eólicos utilizados para el estudio

Tabla 8.3: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas

Tabla 8.4: Resultados de la eficiencia de los modelos según la hipótesis 1

Tabla 8.5: Caso para la hipótesis 2 y WF-1

8.1 Introducción

La curva de potencia de un aerogenerador es un modelo que sirve para estimar la potencia eléctrica que este puede generar en un instante dado a partir de la velocidad estimada del viento o para estimar la energía eléctrica generada por éste durante un periodo de tiempo determinado. La curva de potencia se certifica sometiendo al aerogenerador a unas condiciones de velocidad de viento determinadas, [1] y es independiente de otros parámetros como pueden ser la dirección en la que incide el viento, las condiciones del terreno donde se ubique dicho aerogenerador (rugosidad) o si éste se encuentra sólo o forma parte de un conjunto instalado en el mismo emplazamiento o en zonas anexas. En este último caso habría que considerar, a la hora de estimar la potencia eléctrica, las pérdidas energéticas debido a las estelas que se generan entre los aerogeneradores [1].

Por otro lado, el aerogenerador como cualquier otra máquina sufre durante el proceso de funcionamiento un envejecimiento que conlleva que su funcionamiento diste cada vez más del previsto según su curva de potencia inicial. Es por ello que la incertidumbre a la hora de realizar predicciones de la potencia eléctrica o de generación energética es cada vez mayor, debido a que la curva de potencia, así calculada, se trata de un modelo estático y referido al momento en el que éste es instalado.

La generación a gran escala de energía eléctrica de origen eólico requiere cada vez más de modelos mediante los cuales se puedan predecir, para el parque eólico en su conjunto, la potencia eléctrica en un instante determinado o la generación de energética del mismo. Todo ello con el objeto, entre otras cosas, de poder integrar éstos en los mercados eléctricos donde se necesita optimizar la predicción de potencia o para poder hacer estimaciones más precisas de la generación anual de energía y por lo tanto de los ingresos de este tipo de instalaciones.

8.2 Objetivo

El objetivo general del estudio realizado en este capítulo es el desarrollo de un modelo dinámico de curva de potencia global para un parque eólico utilizando técnicas de inteligencia artificial como son las redes neuronales. Se aplicará a dos parques eólicos reales ubicado en las islas de Gran Canaria y Lanzarote, sitas en el archipiélago canario

El modelo que se pretende desarrollar es dinámico debido a que se genera inicialmente a partir de la información histórica de velocidad y dirección del viento así como de producción pero que se irá adaptando (modificando) a medida que pase el tiempo y se vaya disponiendo información adicional. En definitiva, será un modelo adaptativo y servirá para predecir en cada momento la producción energética del parque eólico en su conjunto.

Objetivos específicos:

- Comparación de los resultados obtenidos con el modelo dinámico de curva de potencia de parque eólico y el modelo estático de curva de potencia de aerogenerador.
- Análisis de las mejoras en la precisión del modelo dinámico cuando se incorpora a la capa de entrada de la red neuronal la información de una estación anemométrica adicional ajena a la de referencia del parque eólico.
- Análisis del comportamiento del modelo dinámico cuando en la capa de entrada se utiliza información de una estación anemométrica ajena al parque eólico en lugar de la propia de referencia de éste.

8.3 Metodología

La figura 8.1 muestra de forma esquemática la metodología general para la generación de los modelos dinámico de curva de potencia de parque eólico utilizando las redes neuronales. Las neuronas de la capa de entrada se corresponden con la información meteorológica (velocidad y dirección del viento) de una o varias estaciones anemométricas. La capa de salida tendrá una única neurona que se corresponda con la potencia global del parque eólico.

El modelo se genera a partir de la información disponible de un año. Los datos disponibles son medias horarias. La información total del año se divide aleatoriamente en tres partes: Entrenamiento, Validación y Test. Las dos primeras servirán para generar el modelo y la última, junto con el modelo generado, servirá para estimar la potencia del parque eólico y poder así valorar la precisión del propio modelo.

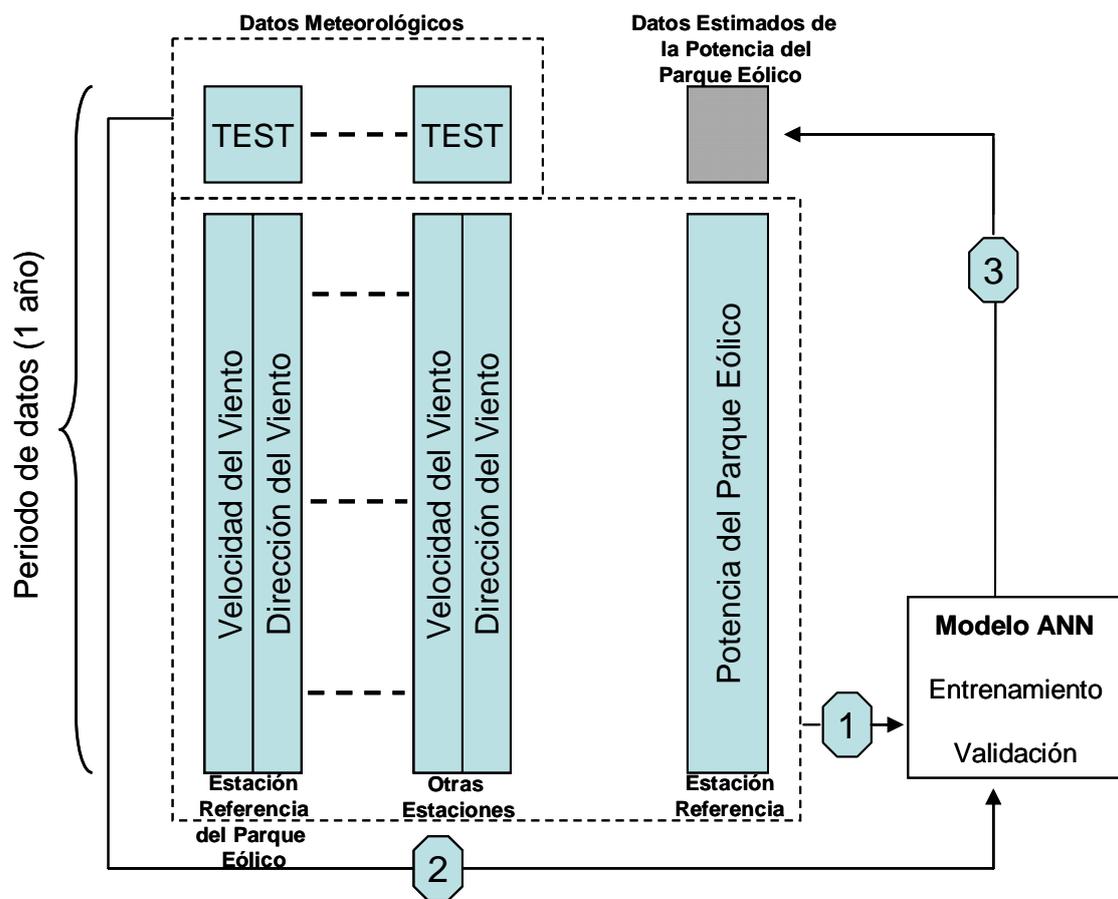


Figura 8.1: Fases de los procesos de estimación de las velocidades y direcciones del viento

A partir del desarrollo metodológico explicado anteriormente se han generado los modelos de ANN para analizar las siguientes hipótesis:

Hipótesis 1) Generación del modelo dinámico de curva de potencia de parque eólico a partir de la información meteorológica (velocidad y dirección del viento) de la estación de referencia del parque. Comparación de los resultados obtenidos entre éste y el modelo de curva de potencia del aerogenerador (modelo estático)

En la figura 8.2 se muestra el esquema de la red neuronal planteada para esta hipótesis. La red neuronal estará formada por una capa de entrada de 2 neuronas (Velocidad y dirección

del viento de la estación de referencia del parque), una capa oculta con 20 neuronas ($k=20$) y la capa de salida con una única neurona (potencia eléctrica del parque eólico)

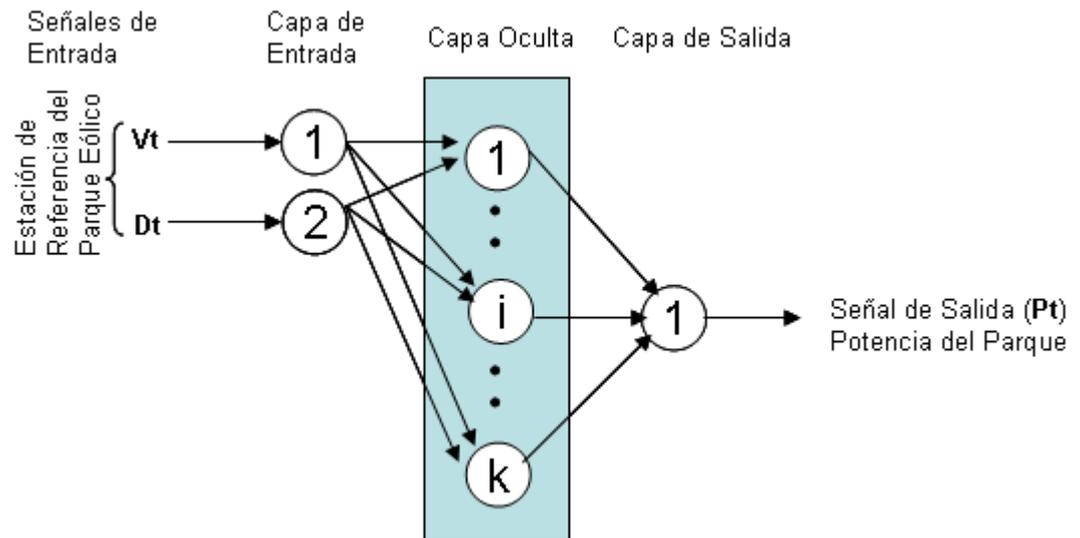


Figura 8.2: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se utiliza únicamente en la capa de entrada la Velocidad y Dirección del viento de la estación de referencia del parque

Los resultados obtenidos con el modelo dinámico de curva de potencia del parque eólico se comparan con los del modelo estático de curva de potencia del aerogenerador.

Para la obtención de los resultados del modelo estático se utiliza la curva de potencia dada por el fabricante. Los fabricantes suelen suministrar las curvas de potencia de sus aerogeneradores en forma discreta con M puntos (P_{wt_i}, v_i) (Ver epígrafe 8.4). La potencia eléctrica obtenible entre dos puntos de la curva de potencia se puede calcularse de forma aproximada [2]. Una de las posibles formas de aproximación consiste en asumir que la variación entre dos puntos de la curva de potencia es lineal (Ecuación 8.1). El resultado así obtenido para un aerogenerador se multiplica por el número aerogeneradores del parque eólico y por un factor, que variará entre 0 y 1, que considera las pérdidas energéticas por la estela generada entre las máquinas eólicas. De esta forma se obtiene, con el modelo estático, la potencia eléctrica del parque eólico en un instante dado.

$$(Ecuación: 8.1) \quad PWT(v) = \frac{Pwt_{i+1} - Pwt_i}{v_{i+1} - v_i} (v - v_i) + Pwt_i$$

Hipótesis 2) Análisis de las mejoras en la precisión del modelo dinámico cuando se incorpora a la capa de entrada de la red neuronal la información de una estación anemométrica adicional ajena a la de referencia del parque eólico.

La figura 8.3 muestra el esquema de la red neuronal para esta hipótesis. La misma, a diferencia del modelo dinámico de la hipótesis 1, tendrá una capa de entrada con 4 neuronas al incorporarle adicionalmente los datos de velocidad y dirección del viento de una estación anemométrica ajena al parque eólico.

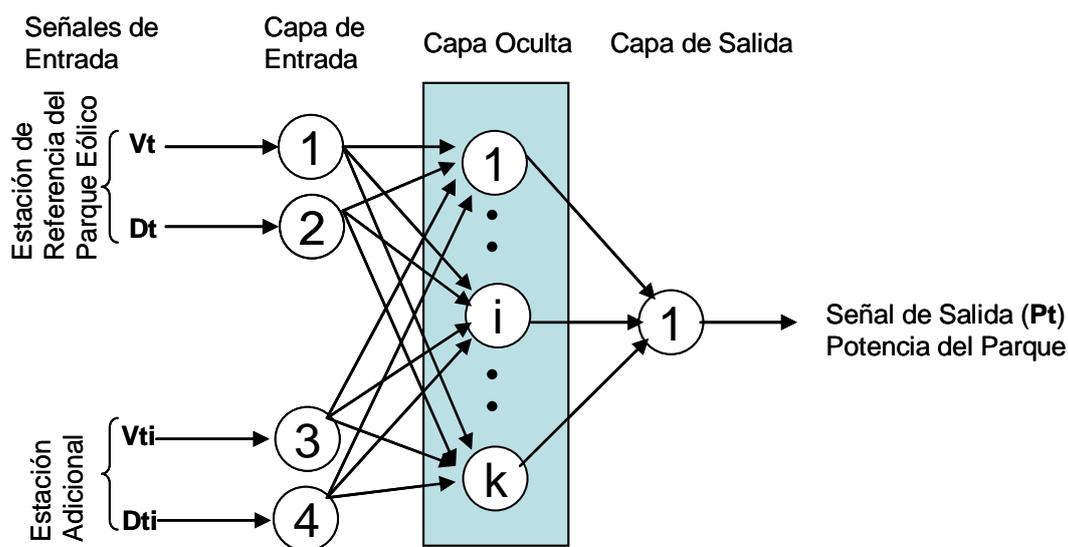


Figura 8.3: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando se incorpora, adicionalmente, los datos de velocidad y dirección de una estación ajena al parque eólico

El número de estaciones anemométricas totales que se han utilizado en estudio es de 9 (incluidas las dos de referencias de los parques eólico utilizados en el estudio). Para este caso se ha combinado la estación de referencia del parque eólico con las otras 7 ajenas a cualquiera de los dos parques en estudio. En este sentido se han generado 7 modelos diferentes para cada uno de los dos parques eólicos.

Hipótesis 3) Análisis del comportamiento del modelo dinámico cuando en la capa de entrada se utiliza información de una estación anemométrica ajena al parque eólico en lugar de la propia de referencia de éste.

Existen casos en el que, bien por problemas en la adquisición de la información meteorológica en la estación de referencia del parque eólico, o por no disponer éste de estación anemométrica, no se tenga información meteorológica de referencia del mismo o ésta esté incompleta. Por ello y con el objeto de poder solucionar este tipo de situaciones, se han generado modelos partir de estaciones ajenas al parque eólico y se han comparado sus resultados con el modelo dinámico generado según la hipótesis 1.

En la figura 8.4 se muestra el esquema del modelo de red neuronal para esta hipótesis. El número de neuronas en las diferentes capas es igual al de la hipótesis 1 pero difiera de ésta en que las neuronas de la capa de entrada se corresponden con los datos de velocidad y dirección del viento de una estación ajena al parque eólico.

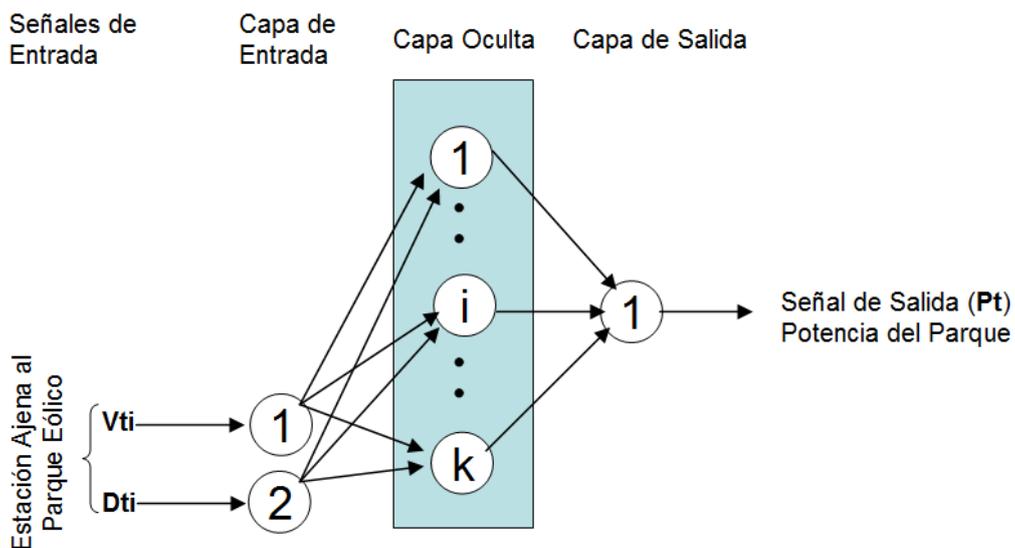


Figura 8.4: Esquema de la red neuronal para generar el modelo dinámico de la curva de potencia del parque eólico cuando en la capa de entrada se utiliza exclusivamente la información de velocidad y dirección del viento de una estación ajena al parque eólico

8.3.1 Métricas utilizadas para la comparación de los diferentes modelos.

Para poder comparar la precisión de los diferentes modelos generados tanto en el caso A como en el B, se han utilizado las siguientes métricas

$$(Ecuación 8.2) \quad MARE = \frac{1}{n} \sum_{i=1}^n \frac{|T_i - O_i|}{T_i}$$

Donde:

MARE, es el error absoluto relativo medio

T_i , Es el valor real de la potencia eléctrica del parque eólico

O_i , Es el valor estimado con los modelos de la potencia eléctrica del parque eólico.

n , es el número de datos de la fase test (Figura 8.1)

$$(Ecuación 8.3) \quad R = \frac{\sum_{i=1}^n (T_i - \bar{T}) \times (O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2} \times \sqrt{\sum_{i=1}^n (O_i - \bar{O})^2}}$$

Donde:

R , es la correlación existente entre los valores estimados y reales de la potencia eléctrica del parque eólico.

\bar{T} , es el valor medio de la potencia eléctrica real para la serie de datos de la fase test (figura 8.1).

\bar{O} , es el valor medio de la potencia eléctrica estimada para la serie de datos de la fase test (figura 8.1).

$$(Ecuación 8.4) \quad I_oA = 1 - \frac{\sum_{i=1}^n (T_i - O_i)^2}{\sum_{i=1}^n (|T_i - \bar{O}| + |O_i - \bar{O}|)^2}$$

Donde:

I_oA (siglas en inglés de Index of Agreement), es la métrica que valora el índice de acuerdo ente los valores estimados por el modelo y los valores reales de la potencia eléctrica del parque eólico. [3,4]. Esta métrica tomará valores entre 0 y 1. Valores más próximos a la unidad significa un mejor ajuste del modelo desarrollado.

8.4 Datos de partida utilizados en el estudio

Los modelos generados en el presente estudio según se explicó en el epígrafe 8.3, se han aplicado a dos parques eólicos (WF) reales instalados en dos islas del archipiélago canario. Cabe resaltar que los dos parques eólicos (WF-1 y WF-2) son diferentes entre sí. De éstos se dispone de la información de producción relativa al año 2008 con una frecuencia horaria así como la disponibilidad de los mismos durante ese año. El parque eólico 1 (WF-1) (Fig. 8.5) se encuentra en la isla de Gran Canaria. Está constituido por 4 aerogeneradores de la marca Gamesa [5] modelo G47 de 660 kW de potencia unitaria. La figura 8.6 muestra la curva de funcionamiento de dichos aerogeneradores. Éstos se encuentran situados en la costa este de la isla de Gran Canaria muy cerca del mar en una zona con pocos accidentes orográficos ni obstáculos artificiales. Están distribuidos en dos líneas prácticamente perpendiculares a la dirección predominante del viento en la zona. La distancia entre aerogeneradores de una misma línea y entre líneas es de 2 y 5,9 veces el diámetro del rotor del aerogenerador, respectivamente.

El parque eólico 2 (WF-2) (Fig. 8.7) está situado en una zona interior de la isla de Lanzarote. Está constituido por 9 aerogeneradores de la marca Gamesa modelo G52 de 850 kW de potencia unitaria. La figura 8.8 muestra la curva de funcionamiento de dicho modelo de aerogenerador. Los aerogeneradores están distribuidos formando prácticamente una línea algo irregular y con una distancia entre éstos, según la perpendicular a la dirección predominante del viento, que oscila entre 2 y 2,5 veces el diámetro de su rotor.



Figura 8.5: Distribución en planta del parque eólico WF-1 en Gran Canaria

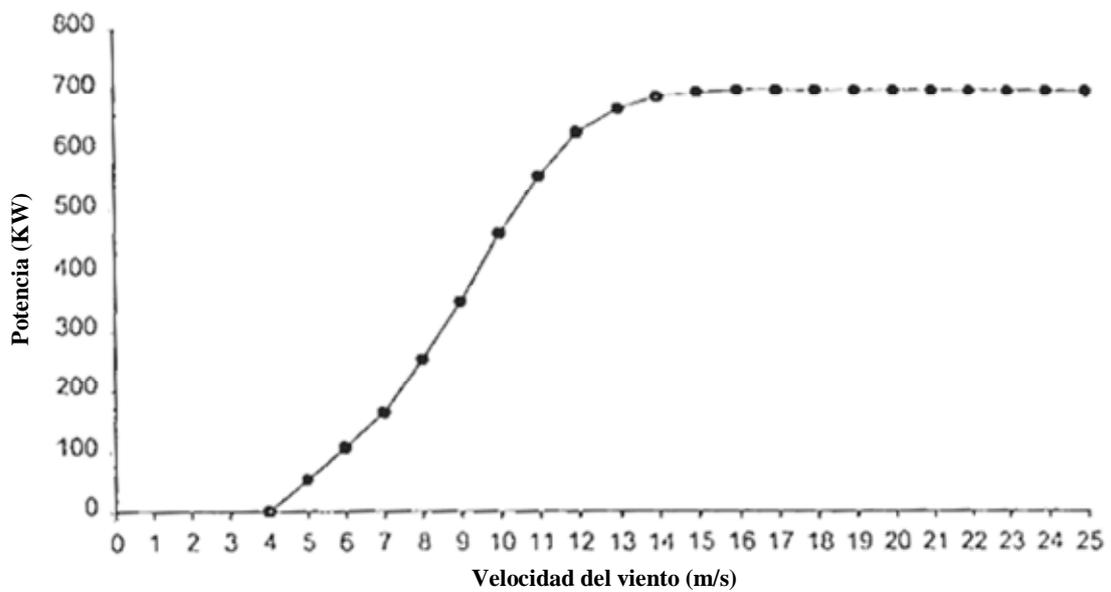


Figura 8.6: Curva de funcionamiento del aerogenerador GAMESA G47/660kW



Figura 8.7: Ubicación del parque eólico WF-2 en Lanzarote

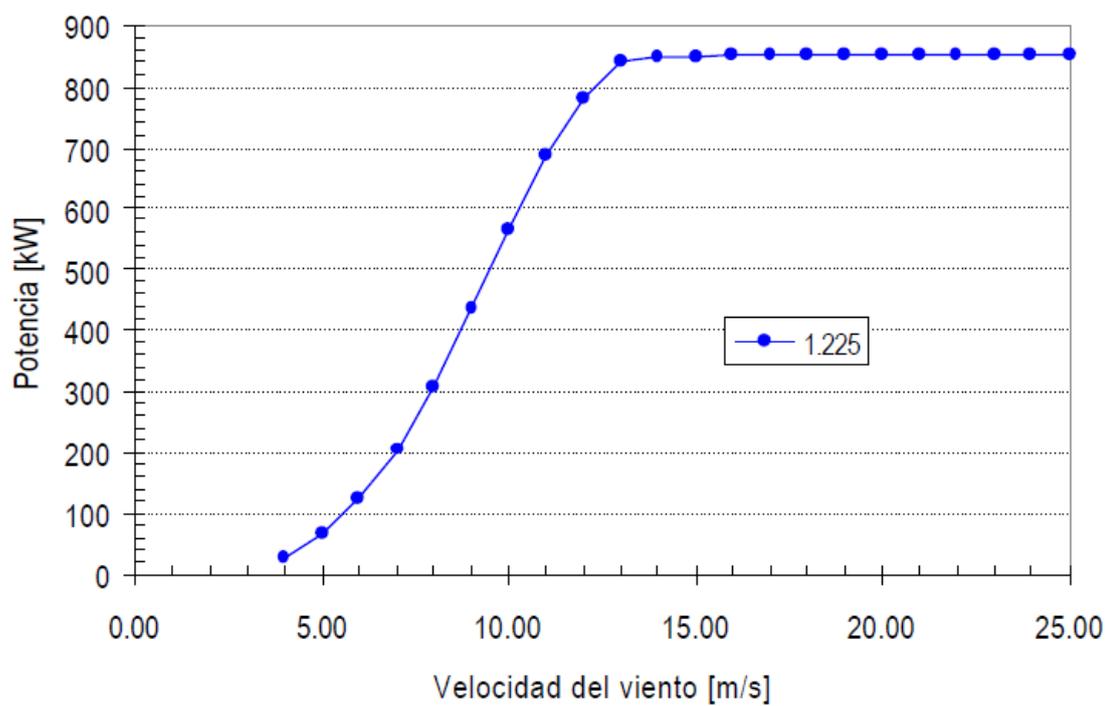


Figura 8.8: Curva de funcionamiento del aerogenerador GAMESA G52/850kW

Los datos meteorológicos utilizados (velocidades y direcciones medias horarias del viento) han sido registrados en nueve estaciones meteorológicas (WS) instaladas en cuatro de las siete islas que componen el archipiélago canario, España (Fig. 8.9). WS-1 y WS-9 son las estaciones de referencia de los parques eólicos WF-1 y WF-2, respectivamente. Se dispone de la información con una frecuencia de medias horarias correspondiente al año 2008. Puede observarse que todos los dispositivos de registro están situados en las costas de las islas, con excepción de la estación WS-9, que está situada en la parte central norte de la isla de Lanzarote. Las series de datos utilizados han sido cedidas por el Instituto Tecnológico de Canarias (ITC).

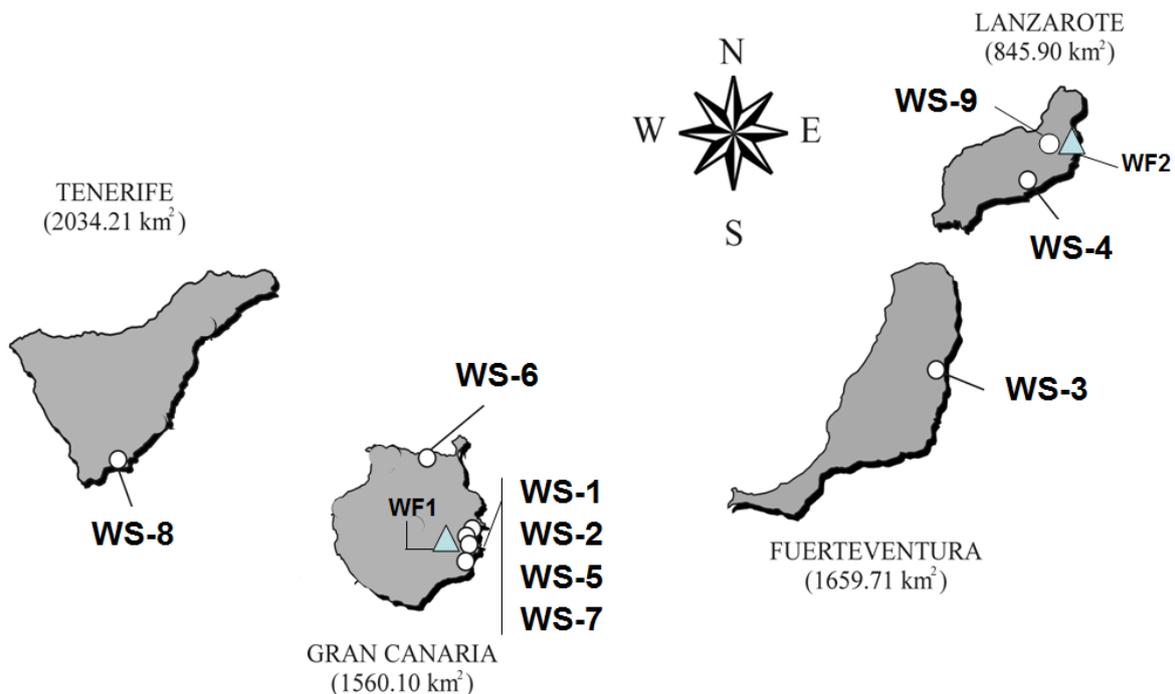


Figura 8.9: Ubicación de las estaciones anemométricas (WS) y parques eólicos (WF) utilizados en el estudio

La tabla 8.1 muestra una información resumen de cada una de las estaciones anemométrica. Se exponen los códigos asignados a cada una de ellas, la altura sobre el nivel del suelo, las coordenadas geográficas (latitud, longitud y altitud) y la velocidad media anual.

Tabla 8.1: Estaciones meteorológicas utilizadas en el estudio

Código (WS)	Altura (m)	Latitud (N)	Longitud (W)	Altitud (m)	Velocidad media anual (m/s)
WS-1	40	27°54'08"	15°23'17"	16	8,8
WS-2	10	27°51'36"	15°23'13"	3	7,7
WS-3	10	28°27'10"	13°51'54"	24	5,6
WS-4	10	28°57'7"	13°36'	10	5,4
WS-5	13	28°01'36"	15°23'16"	5	6,9
WS-6	10	28°07'30"	15°40'37"	472	8,5
WS-7	10	27°56'08"	15°25'24"	186	6
WS-8	10	28°02'35"	16°34'16"	51	6
WS-9	40	29°05'47"	13°30'21"	457	8,4

En la Tabla 8.2 se expone información general de los dos parques eólicos en estudio.

Tabla 8.2: Parques eólicos utilizados para el estudio

Código del Parque Eólico	Isla	Rendimiento Energético del Parque (MWh/MW)	Estación de referencia del parque eólico
WF-1	Gran Canaria	3645	WS-1
WF-2	Lanzarote	3450	WS-9

En la Tabla 8.3 se muestra los coeficientes de correlación lineal (CC) (Ecuación 8.5) entre las velocidades medias horarias del viento de las diferentes estaciones. El rango de coeficientes de correlación oscila entre 0.10 y 1. El valor más bajo ha sido obtenido entre las estaciones WS-3 y WS-9. Los coeficientes de correlación más altos se han observado entre los datos medidos en los dispositivos de registro de las estaciones (WS-1 y WS-2) y (WS-2 y WS-7).

Tabla 8.3: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas

	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-7	WS-8	WS-9
WS-1	1,000	0,841	0,275	0,343	0,745	0,736	0,775	0,503	0,505
WS-2	0,841	1,000	0,192	0,251	0,790	0,744	0,871	0,444	0,543
WS-3	0,275	0,192	1,000	0,702	0,166	0,162	0,181	0,161	0,109
WS-4	0,343	0,251	0,702	1,000	0,209	0,215	0,227	0,201	0,111
WS-5	0,745	0,790	0,166	0,209	1,000	0,493	0,780	0,218	0,443
WS-6	0,736	0,744	0,162	0,215	0,493	1,000	0,610	0,621	0,541
WS-7	0,775	0,871	0,181	0,227	0,780	0,610	1,000	0,397	0,462
WS-8	0,503	0,444	0,161	0,201	0,218	0,621	0,397	1,000	0,346
WS-9	0,505	0,543	0,109	0,111	0,443	0,541	0,462	0,346	1,000

(Ecuación 8.5)
$$CC = \frac{\sum_{i=1}^m (v_{1i} - \bar{v}_1) \times (v_{2i} - \bar{v}_2)}{\sqrt{\sum_{i=1}^m (v_{1i} - \bar{v}_1)^2} \times \sqrt{\sum_{i=1}^m (v_{2i} - \bar{v}_2)^2}}$$

Donde:

CC, es el coeficiente de correlación entre las velocidades de dos estaciones anemométricas

V_1 y V_2 , son los datos de velocidad de las dos estaciones anemométricas

m, es el número de datos que se disponen en el año

\bar{V}_1 y \bar{V}_2 , son los valores medios de las velocidades de las dos estaciones.

La Figura 8.10 muestra la distribución de frecuencia de direcciones en la zona donde se encuentran los dos parques eólicos en estudio.

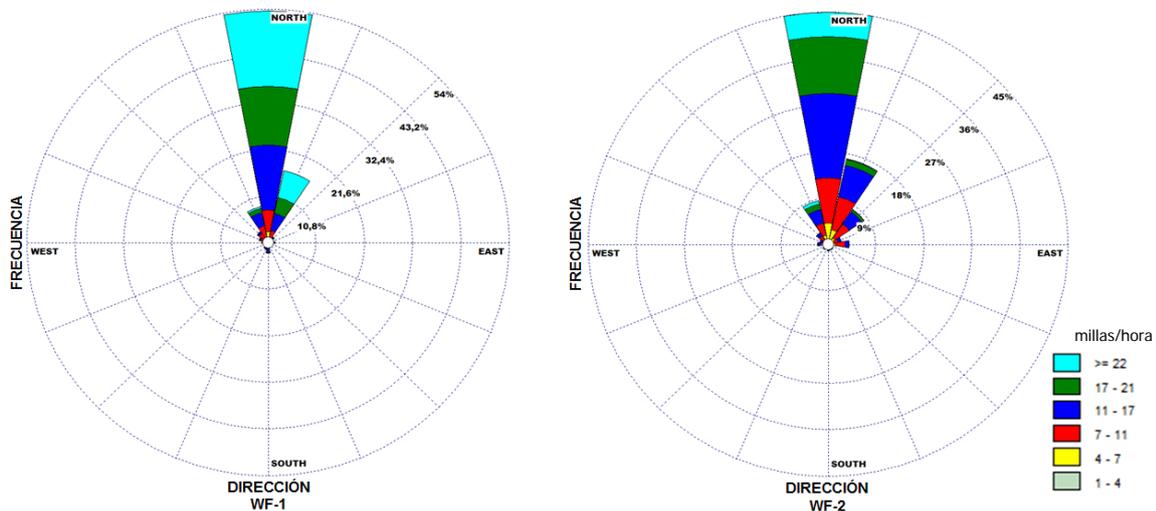


Figura 8.10: Rosas de los vientos de las estaciones de referencia de los parques eólicos WF-1 y WF-2, respectivamente

8.5 Arquitectura de las Redes Neuronales utilizadas.

Las ANN 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) [6-7]. 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 [6-7] y ha sido propuesta por diversos autores [8-10]. 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. En todas de las hipótesis consideradas la capa de salida tiene una sola neurona. La señal de salida proporcionada por dicha neurona es la potencia del parque objetivo.

Las arquitecturas diseñadas han sido entrenadas usando el algoritmo de Backpropagation con función de activación sigmoideal [6-7]. Como algoritmo de minimización del error cuadrático medio cometido en el aprendizaje se ha utilizado el de Levenberg-Marquard [6,11].

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 o test [12]. La proporción de datos seleccionada para cada una de los procesos ha sido de 70%,15% y 15%, respectivamente.

El subconjunto de datos de entrenamiento se utiliza para la estimación de los pesos de la ANN. El subconjunto de validación es utilizado para chequear el progreso del entrenamiento de las ANN, optimizando los parámetros de las mismas. Es decir, se utilizan para medir el grado de generalización de las ANN. El subconjunto de los datos de ensayo o test, que no han sido utilizados ni en la etapa de entrenamiento ni de validación, es usado para calcular la precisión del modelo de red neuronal generado. Es decir, constituye una medida independiente del funcionamiento de la red después del entrenamiento.

Los distintos experimentos han sido realizados empleando las herramientas que para las redes neuronales presenta el software informático Matlab [13]. Los requisitos mínimos de memoria RAM para la generación de todos los modelos es de 4GB.

8.6 Discusión de los resultados obtenidos

8.6.1 Resultados hipótesis 1

El estudio realizado según la hipótesis 1 compara la precisión en la estimación de la potencia eléctrica de un parque eólico, utilizando el modelo estático (modelo de curva de potencia del aerogenerador) y el dinámico desarrollado en el presente estudio (modelo de curva de potencia de parque eólico global obtenido aplicando las técnicas de las redes neuronales artificiales). A éste último se le ha denominado ANN-DWFPC. En la tabla 8.5 se observan los resultados obtenidos para la precisión de los modelos según las diferentes métricas empleadas. Para los dos parques eólicos en estudio el modelo dinámico desarrollado en el presente estudio mejora los resultados que se obtienen con el modelo estático.

Para el parque eólico 1 (WF-1) los resultados obtenidos con el modelo estático son inicialmente muy malos, mejorándose en gran medida al aplicar el modelo dinámico. Con este último, el error (MARE) se reduce de 0,7302 a 0,2239, mientras que el IoA mejora de 0,6046 a 0,9637.

Para el caso del parque eólico 2 (WF-2) los resultados también mejoran con el modelo dinámico, disminuyéndose el error (MARE) de 0,1822 a 0,0956, prácticamente se reduce un 50%.

Tabla 8.4: Resultados de la eficiencia de los modelos según la hipótesis 1

Parque eólico	Resultados Modelo Estático			Resultados Modelo Dinámico (ANN-DWFPC)		
	MARE	R	IoA	MARE	R	IoA
H1-WF-1	0,7302	0,9151	0.6046	0,2239	0,9317	0,9637
H1-WF -2	0,1822	0,9654	0.9768	0,0956	0,9820	0,9909

Los resultados obtenidos inicialmente con el modelo estático difieren en gran medida según su aplicación al WF-1 ó al WF-2. Se obtienen unos resultados muchos peores para el caso del WF-1. El parque eólico 1 está constituido por 2 líneas de aerogeneradores perpendiculares a la dirección predominante del viento, mientras que el parque eólico 2 está formado por una única línea de aerogeneradores. Un mayor número de líneas de aerogeneradores implica el aumento del efecto estela entre éstos y por lo tanto de la pérdida energética de los aerogeneradores en particular y del parque eólico en general. Además, cuanto más próximas estén las líneas de aerogeneradores, mayor será la estela entre ambas [1]. En definitiva se deduce, que el modelo estático genera mucha incertidumbre cuando la configuración del parque eólico es más compleja. Este hecho no es tan apreciable para el caso del modelo dinámico que, si bien existe una diferencia entre los resultados para ambos parques, ésta no es tan acuciante como para el primero. Se deduce de los resultados obtenidos para esta hipótesis 1, que las mejoras que aporta el modelo dinámico son mucho más importantes en el parque eólico 1, el que presenta una configuración más compleja y por lo tanto un mayor efecto de las estelas entre aerogeneradores.

8.6.2 Resultados hipótesis 2

Los modelos dinámicos generados según la hipótesis 2, presentan en la capa de entrada de la ANN dos neuronas adicionales relativas a la información de velocidad y dirección del viento de una estación adicional ajena a la de referencia del parque eólico. Tal y como se explicó en el punto 8., se combinaron 7 estaciones adicionales con la de referencia de cada uno de los parques eólico, obteniéndose otros tantos modelo. Las estaciones combinadas adicionalmente son de la WS-2 a la WS-8 (Tabla 8.1). Los casos han sido codificados según se muestra en la tabla 8.6. El caso 0 se corresponde con el obtenido según la hipótesis 1, donde sólo se incorpora la estación de referencia del parque eólico. Con éste se compararán el resto de los casos.

Tabla 8.5: Caso para la hipótesis 2 y WF-1

Hipótesis 2	Estación adicional
H2-WF1 caso 0	Ninguna
H2-WF1 caso 1	WS-2
H2-WF1 caso 2	WS-3
H2-WF1 caso 3	WS-4
H2-WF1 caso 4	WS-5
H2-WF1 caso 5	WS-6
H2-WF1 caso 6	WS-7
H2-WF1 caso 7	WS-8

Las figuras 8.11 y 8.12 muestran los resultados para el MARE y el coeficiente de correlación "R", respectivamente, obtenidos al aplicar los diferentes modelos al parque eólico WF-1. Se observa que todos los casos de esta hipótesis mejoran los resultados obtenidos según la hipótesis 1 (H2-WF1 Case 0). El grado de mejora de los resultados es independiente de la correlación existente entre la estación de referencia del parque eólico y la adicional añadida. Para el caso particular "H2-WF-1 caso 1", las mejoras en el "MARE" y la "R" llegan a ser del 17,6% y el 1,9%, respectivamente.

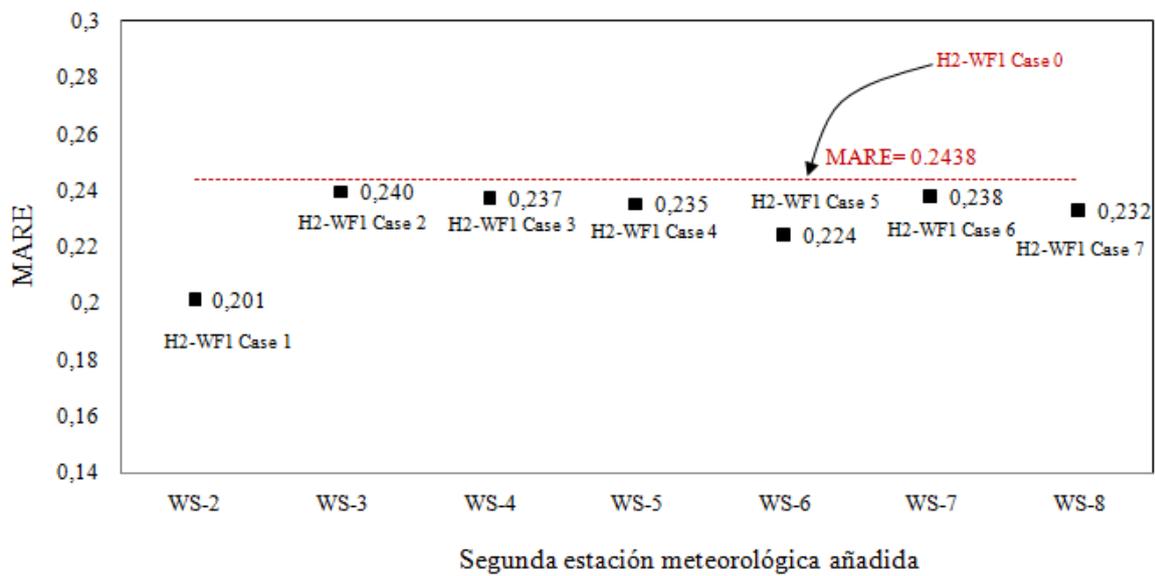


Figura 8.11: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-1

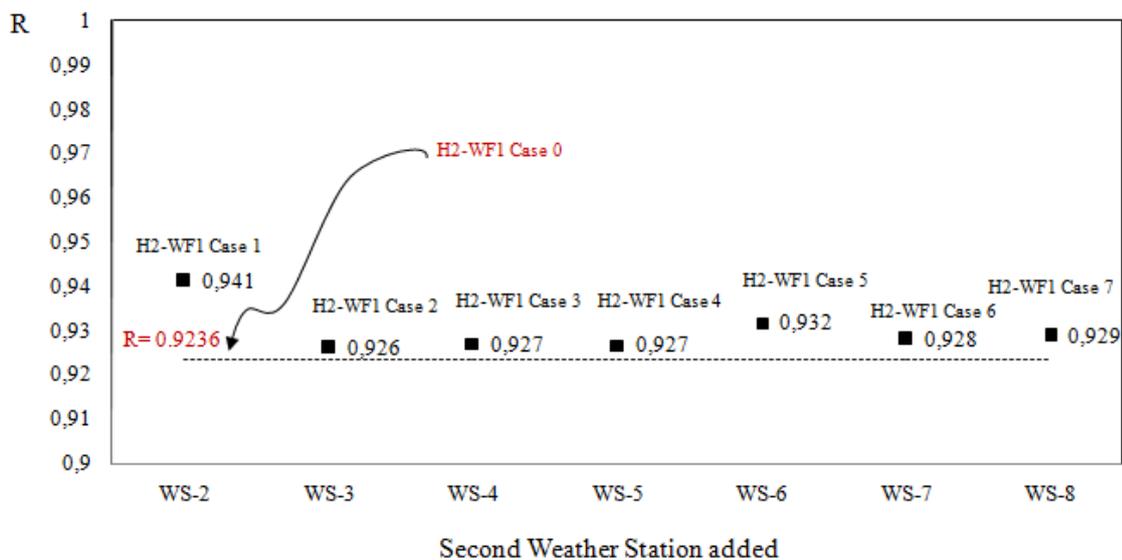


Figura 8.12: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-1

En las figuras 8.13 y 8.14, se muestran los resultados de la aplicación de los modelos de la hipótesis 2 al parque eólico WF-2. La eficiencia del modelo inicial (H2-WF2 caso 0) para este parque eólico era mucho mejor que para el caso del WF-1, tal y como se explicó en los resultados de la hipótesis 1. En este sentido, se observa que al añadir la estación adicional, los resultados prácticamente se mantienen constantes en torno a los datos iniciales.

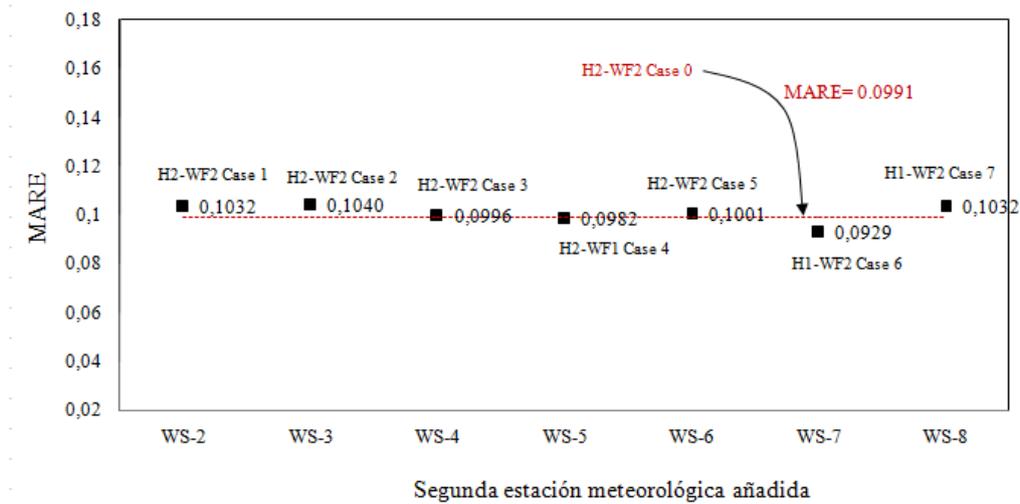


Figura 8.13: Resultados del MARE para la hipótesis 2. Caso particular del parque eólico WF-2

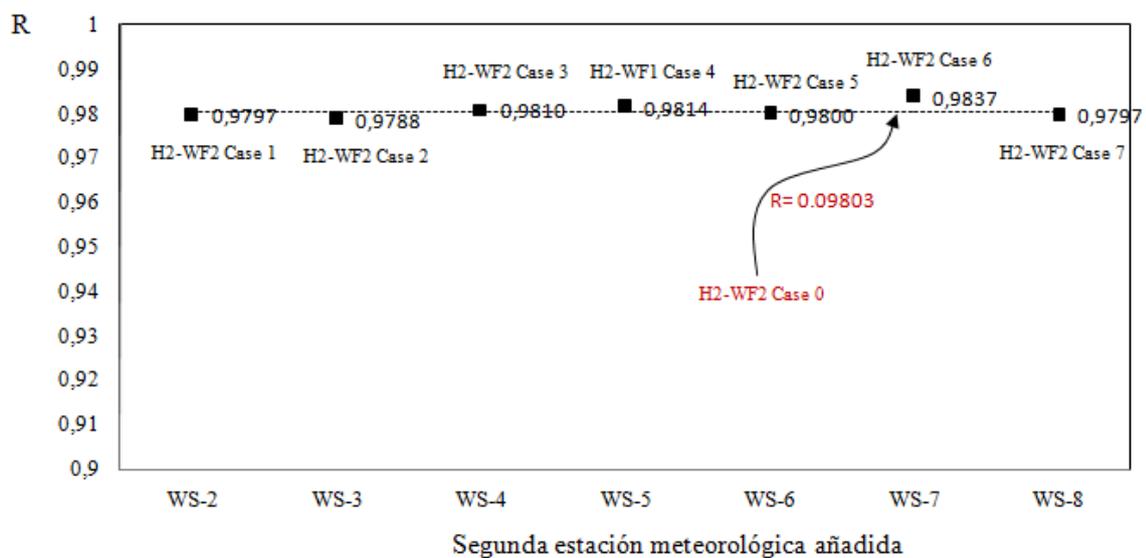


Figura 8.14: Resultados de la "R" para la hipótesis 2. Caso particular del parque eólico WF-2

La figura 8.15 muestra los resultados obtenidos para el IoA (Ec. 8.4), otra de las métricas utilizadas para estudiar y comparar el rendimiento de los modelos. Los resultados siguen la misma tendencia que la explicada para el "MARE" y la "R". Es decir, para el caso del WF-1 todos los modelos de la hipótesis 2 mejoran el resultado inicial obtenido con una sola estación (H2-WF-1 Case 0), mientras que para el WF-2, prácticamente los resultados se mantiene en torno al inicial.

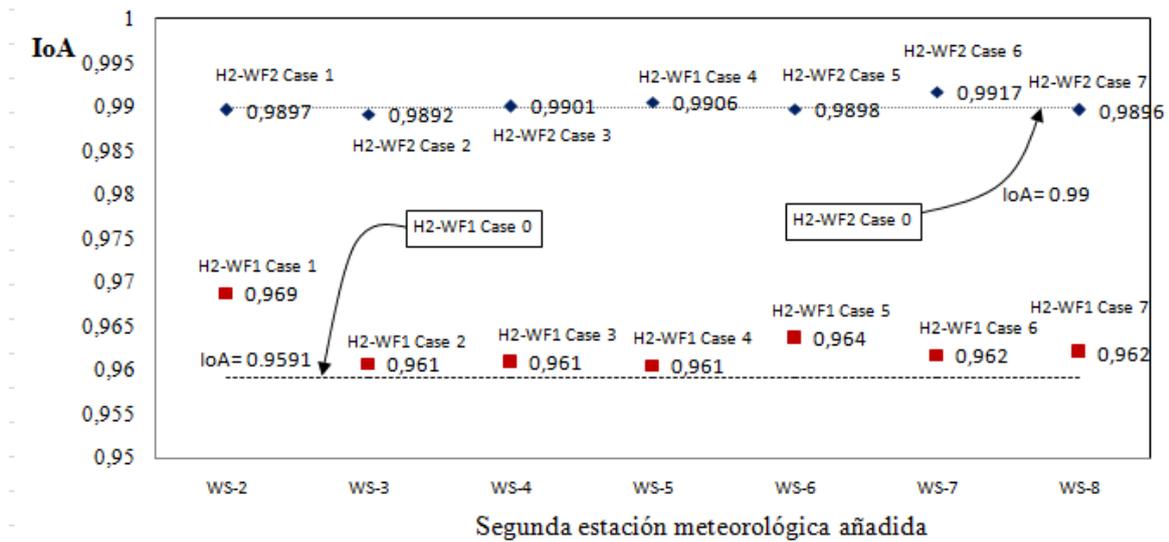


Figura 8.15: Resultados del IoA para la hipótesis 2. Casos particulares de los parques eólicos WF-1 y WF-2

8.6.3 Resultados hipótesis 3

En la figura 8.15 se muestran los resultados obtenidos según los modelos desarrollados para la hipótesis 3. En la misma figura se han representado los resultados en la aplicación de los modelos a ambos parques eólico (WF-1 y WF-2). Es decir, los resultados con los 14 modelos generados, 7 para cada parque.

Cada punto representa la relación que existe entre el coeficiente de correlación entre la estación utilizada para la generación del modelo y la de referencia del parque eólico ("CC"), y el valor obtenido para la métrica IoA en esta hipótesis 3, expresado en relación al obtenido para el caso 0. Se observa que cuanto mayor sea el coeficiente de correlación entre las velocidades de las estaciones de referencia del parque y la utilizada para la generación del modelo ("CC"), mayor será el grado de similitud entre los modelos dinámicos (DWFPC) obtenidos según la hipótesis 1 y 3 ($H3-IoA/IoA-case0$). Para valores de CC superiores a 0,7 el grado de similitud, expresado como el cociente de los IoA, es superior a 0,9.

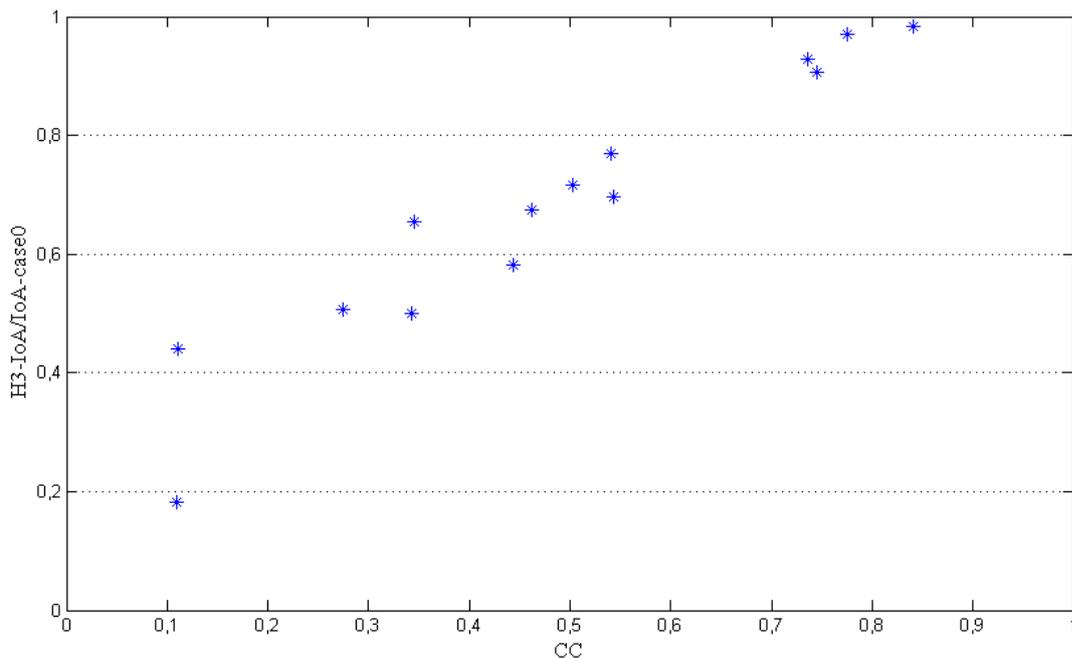


Figura 8.16: Grado de similitud en la precisión de los modelos dinámicos calculados según las hipótesis 1 y 3

8.7 Conclusiones al capítulo.

En el presente capítulo se ha desarrollado un modelo dinámico de curva de potencia global de parque eólico para la estimación de la potencia eléctrica del mismo. Para ello se han utilizado técnicas de inteligencia artificial como son las redes neuronales.

El modelo generado se ha comparado con los resultados obtenidos en la estimación de la potencia global del parque utilizando el modelo estático de curva de potencia del aerogenerador. Por otro lado, se ha analizado las mejoras potenciales del modelo dinámico al utilizar información adicional en la capa de entrada de la red neuronal.

Por último, con el objeto de solucionar los casos en los que el parque eólico no disponga de información meteorológica de referencia o bien ésta presente defectos, se ha estudiado la posibilidad de utilizar una estación ajena al mismo para la generación del modelo. Para ello, se ha analizado el grado de similitud entre los modelos dinámicos generados con la estación de referencia del parque y con esa otra estación ajena.

Entre las conclusiones obtenidas en los estudios llevados a cabo en el presente capítulo, cabe destacar las siguientes:

- Los modelos dinámicos de curva de potencia de parque eólico desarrollado utilizando las ANN's (DWFPC) mejoraron, para los dos parques eólicos en estudio, los resultados obtenidos utilizando el modelo estático de curva de potencia de aerogenerador.
- El grado de mejora en la precisión del modelo dinámico con respecto al estático fue tanto mayor cuanto mayor era la complejidad en la distribución de los aerogeneradores sobre el terreno. Para el caso del WF-1 el error del modelo, MARE, se redujo en un 69.3%, mientras que para el caso del WF-2 la reducción fue del 47,5%.
- Para el caso del WF-1, parque donde existía una mayor complejidad en la distribución de los aerogeneradores sobre el terreno (dispone de varias líneas de aerogeneradores según la dirección perpendicular a la predominante del viento), los modelos dinámicos obtenidos según la hipótesis 2, en la cual se le añadía una estación adicional a la capa de entrada de la ANN, mejoraron en todos los casos los resultados obtenidos según el modelo dinámico de la hipótesis 1. El grado de mejora para el MARE llegó a ser del 17,6%.

Para el caso particular del WF-2, donde ya inicialmente los resultados obtenidos para la precisión del modelo dinámico, según la hipótesis 1, eran muy buenos ($MARE < 0,1$), los resultados de los modelos generados según la hipótesis 2 fueron similares al primero.

- Cuando se utilizaron, como neuronas de la capa de entrada de la ANN, los datos meteorológicos de una estación ajena al parque eólico, en lugar de los propios de la estación de referencia del mismo (hipótesis 3), el grado de similitud entre el modelo dinámico así obtenido y el resultante según la hipótesis 1, era tanto mayor cuanto mejor fuera la correlación entre las velocidades de las estaciones de referencia y la ajena utilizada ("CC").
- Para un CC superior a 0,75, el grado de similitud entre los modelos dinámicos obtenidos según las hipótesis 1 y 3 fue superior a 0,9 (en una escala de 0 a 1, donde 1 representa el grado similitud óptima - figura 8.15)

8.7 Referencias

- [1] Asociación Española de Normalización y Certificación (AENOR). Medida de la curva de potencia de aerogeneradores productores de electricidad. UNE 61400-12-1.2006
- [2] 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. Article in press. Doi: 10.1016/j.enconman.2010.09.0085.
- [3] Ji L., Gallo K. An Agreement Coefficient for Image Comparison. Photogrammetric Engineering & Remote Sensing, Vol 72, No. 7, 2006: pp. 823–833.
- [4] Willmott C. J., Robeson S. M., Matsuura K. Short Communication A refined index of model performance. INTERNATIONAL JOURNAL OF CLIMATOLOGY, 32. 2008: pp. 2088-2094
- [5] Gamesa Eólica. <www.gamesa.es>
- [6] Principe JC, Euliano NR, Lefebvre WC. Neural and Adaptive Systems. Fundamentals Through Simulations. first ed. New York: John Wiley & Sons, Inc.; 2000.
- [7] Masters T. Practical Neural Network Recipes in C++. first ed. California:Morgan Kaufmann Publishers;1993.
- [8] Oztopal A. Artificial Neural Network approach to spatial estimation of wind velocity. Energy Conversion and Management 2006;47:395–406.
- [9] 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.
- [10] Monfared M, Rastegar H, Kojabadi HM. A new strategy for wind speed forecasting using artificial intelligent methods. Renewable Energy 2009;34:845-48.
- [11] Draper NR; Smith H (1998). *Applied regression analysis*. John Wiley & Sons, Inc, 1966
- [12] Witten IH, Frank E. Data Mining. Practical Machine Learning Tools and Techniques. 2nd ed. San Francisco: Elsevier;2005.
- [13] Demuth H. Beale M. Neural network toolbox user's guide. The Math Works, Inc., Natick, MA 01760-2098;2003.

CAPITULO 9

Análisis de la influencia de los datos de la capa de entrada de un modelo de Red Neuronal Artificial en la predicción a corto plazo de la potencia eléctrica de un parque eólico.

INDICE

9.1 Introducción.....	279
9.2 Objetivo.....	282
9.3 Metodología.....	283
9.4 Datos de partida.....	288
9.5 Arquitectura de las Redes Neuronales utilizadas.....	291
9.6 Discusión de los resultados obtenidos.....	292
9.7 Conclusiones al capítulo.....	300
9.8 Referencias.....	302

INDICE DE FIGURAS

Figura 9.1: Metodología para la obtención de los modelos de predicción

Figura 9.2: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso A)

Figura 9.3: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso B)

Figura 9.4: Distribución en planta del parque eólico

Figura 9.5: Ubicación de las estaciones anemométricas (WS) y del parque eólico (WF)

Figura 9.6: MARE para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

Figura 9.7: Valor de R para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

Figura 9.8: Variación del MARE para los diferentes periodos de predicción. Caso de un horizonte temporal $t+24$

Figura 9.9: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN

Figura 9.10: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN.

Figura 9.11: Mejora experimentada por el MARE del modelo al incorporar una estación adicional a la capa de entrada de la ANN

Figura 9.12: Mejora experimentada por el R del modelo al incorporar una estación adicional a la capa de entrada de la ANN

INDICE DE TABLAS

Tabla 9.1: Información de las estaciones meteorológicas utilizadas en el estudio

Tabla 9.2: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2008

9.1 Introducción

La contribución de las energías renovables a la demanda de energía eléctrica en Canarias era a finales del año 2014 del 8,1%, según datos publicados por Red Eléctrica de España [1]. Este dato se encuentra muy alejado de la contribución del 40% asignada a España a través de la DIRECTIVA 2009/28/CE DEL PARLAMENTO EUROPEO [2].

El Gobierno de Canarias tiene entre sus estrategias energéticas aumentar la contribución de las energías renovables, y en particular de la energía eólica, a la demanda de la energía eléctrica. El Plan Energético de Canarias 2006-2015 (PECAN) es un documento estratégico que establece, entre sus objetivos, que las energías renovables contribuyan en un 30% a la demanda de energía eléctrica [3, 4]. Para el caso particular de la energía eólica, establece el tener instalados 1.025MW de potencia eólica en el año 2015 que presumiblemente se prorrogará hasta el 2020.

Por lo tanto, el objetivo que para la energía eólica se ha marcado el Gobierno de Canarias, mirado desde la perspectiva de los escasos 156 MW instalados en la actualidad [1], hará que el sector de la energía eólica, como fuente de energía renovable para la generación de energía eléctrica, tenga un marcado interés en los próximos años.

Las pequeñas y débiles redes eléctricas insulares representan una importante restricción técnica a la hora de maximizar la penetración de la energía eólica en las mismas. Esto es debido, entre otros aspectos, a que ésta es una fuente energética no gestionable, por su elevada variabilidad [5-7] y que afecta a la estabilidad del sistema eléctrico insular. Esta afección se incrementará en un escenario de alta penetración de EERR.

En resumen, el crecimiento esperado en la contribución de la energía eólica a la demanda de energía eléctrica de Canarias, teniendo en cuenta la baja gestionabilidad de este recurso y la debilidad de las redes eléctricas insulares, hace preciso el disponer de modelos de predicción a corto plazo, inferior a 48 horas, de la potencia eléctrica de los parques eólicos. De esta forma estos podrán entrar en igualdad de condiciones, respecto al resto de sistema de generación convencional, en un mercado eléctrico liberalizado.

En la literatura científica se pueden encontrar diferentes modelos para la predicción futura de la potencia eléctrica de parques eólicos [8-18]. Éstos presentan diversas fiabilidades o

errores en la estimación que hace que los valores predichos, en muchos casos, disten en gran medida de los valores reales medidos.

Muchos enfoques de predicción han sido estudiados y propuestos, cada uno utilizando una técnica diferente y un buen desempeño con un horizonte de predicción diferente. Recientes estudios en el área de la predicción de viento se centran predominantemente en las predicciones de viento a corto plazo debido a la importancia de estos datos sobre los sistemas de energía. Especialmente en predicciones con días de antelación son de gran interés para las operaciones del sistema tales como la programación, el compromiso y la unidad de carga siguiente. Las diferentes técnicas que están disponibles van desde heurísticas simples a los sistemas de modelización numérica del tiempo completo. Sin embargo, todos los modelos tienen plazos para los que son los más adecuados.

Entre varios métodos, las redes neuronales artificiales (ANN) son excelentes para predecir variables que son no lineales o estocásticas en la naturaleza y por lo tanto han sido utilizados para pronosticar la velocidad y/o potencia del viento. La ventaja de las ANN es que no hay necesidad de basar las predicciones sobre modelos matemáticos preconcebidos. En lugar de ello, la metodología se basa en muestras de datos de entrenamiento para predecir los patrones de la disponibilidad futura de la potencia eólica.

Adel Brka et al [11] muestra que los efectos estacionales deben tenerse en cuenta en las predicciones a largo plazo. La precisión de la predicción se ve fuertemente afectado por la longitud de los datos históricos que se utilizan para la formación de la red neuronal (ANN). En este caso utilizó 168 horas de información meteorológica y de producción para el entrenamiento de la red neuronal. Esta información es la equivalente a dos meses del año, por lo que el modelo no contemplaba las fluctuaciones estacionales del viento Adel et al, también investigan este tema trabajando con valores medios meteorológicos a diferentes intervalos de tiempo (0,5-3 h).

Paras et al [14] utiliza como neuronas de entrada a la red neuronal los datos de velocidad, dirección, temperatura y producciones pasadas y hace estimaciones futuras a 3, 6, 12 y 24 horas. El tiempo de antelación al momento de predicción que utiliza en la capa de entrada es constante para cada horizonte temporal.

Osório et al [15], desarrolla el modelo utilizando los datos históricos de potencia con una antelación de 12h y predice hasta una horizonte temporal de 6h.

Duehee et al [18] desarrolla un modelo para predecir un horizonte temporal de 48h. Para ello utiliza solamente como información de entrada al modelo, las potencias eléctricas históricas.

Tascikaraoglu et al [16] hace una revisión de los diferentes modelos de predicción que utilizan varios autores así como el horizonte de predicción de los mismos. En todos los estudios científicos revisados por Tascikaraoglu et al, además de los revisados por el autor del presente trabajo, la información meteorológica que se considera para el desarrollo del modelo es exclusivamente la relativa a la zona donde se encuentra la instalación eólica. No se considera en ningún momento datos meteorológicos de otras zonas que pudiere dar una información adicional al modelo en la fase de entrenamiento. Además también se ha comprobado que en los modelos analizados la longitud de la información, previa al momento de predicción, que se considera para la predicción de un horizonte temporal dado es siempre constante.

Otro aspecto importante a la hora de validar el modelo que se desarrolle son las métricas que se utilicen para ello. En la mayoría de los estudios científicos analizados, el error en la predicción para un instante de tiempo dado, se relativiza respecto a la potencia media real del horizonte de predicción escogido, Ecuación 9.1, y no en base a cada instante de predicción, Ecuación 9.2. Tal y como se comentó anteriormente, la importancia de la predicción radica en contribuir a una mejor integración de los sistemas eólicos en los mercados eléctricos. Es por ello que se debe tener una medida del error relativo para cada instante de predicción, generalmente cada hora, que se corresponde generalmente con los instantes de compra-venta de la energía.

$$\text{Ecuación 9.1} \quad \frac{|P_{i+j} - O_{i+j}|}{\frac{1}{m} \sum_{j=1}^m P_{i+j}}$$

$$\text{Ecuación 9.2} \quad \frac{|P_{i+j} - O_{i+j}|}{P_{i+j}}$$

Donde:

i , es el instante de tiempo en el que se predice

P_{i+j} , es el valor real de la potencia del parque eólico en el instante de tiempo "i+j"

O_{i+j} , es el valor estimado para la potencia del parque eólico en el instante de tiempo "i+j"

m , es el número de periodos del horizonte temporal que se predice

9.2 Objetivo

El objetivo general del presente capítulo es el desarrollo de un modelo de predicción a corto plazo (<36horas) de la potencia eléctrica generada por un parque eólico utilizando las redes neuronales artificiales.

El estudio pretende analizar la influencia que tienen diferentes parámetros de la capa de entrada de la ANN en la precisión del modelo. Concretamente se estudiará:

- a) El efecto que tiene el tiempo considerado, previo al momento de predicción, para las diferentes variables que intervienen en la capa de entrada de la ANN.
- b) El efecto de la incorporación adicional de la información meteorológica de otras zonas diferentes a la del parque eólico.

Todo ello, con el objeto de optimizar la precisión del modelo desarrollado. Al disponer de los resultados para cada periodo del horizonte temporal (p.e. Ecuación 9.2), esta precisión no sólo se analizará en términos de sus valores medios dentro del horizonte de predicción, sino además de su estabilidad dentro del mismo.

Se estudiará además el efecto de la precisión del modelo en la penalización económica al parque eólico por el posible desvío en la predicción. Esta penalización se encuentra establecida en la legislación española.

Para ello se ha trabajado en base a los datos disponibles para un parque eólico real ubicado en la isla de Gran Canaria (Islas Canarias).

9.3 Metodología

Los diferentes modelos generados a través de las redes neuronales artificiales se basan en la metodología que se muestra en la figura 9.1.

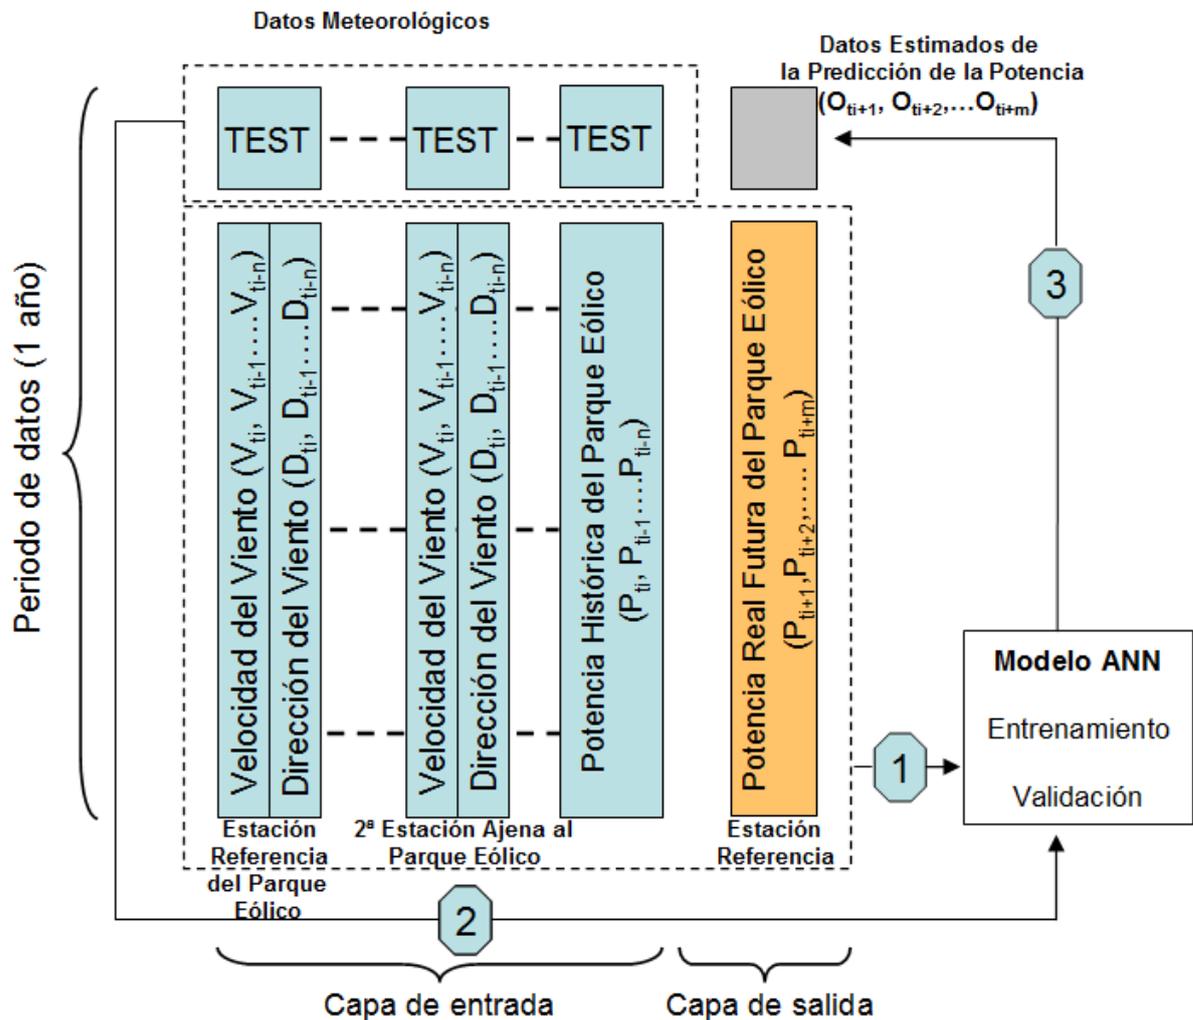


Figura 9.1: Metodología para la obtención de los modelos de predicción

En la figura 9.1 se muestra la combinación de variables que se han considerado para la capa de entrada y de salida de la red neuronal. En la capa de entrada se han utilizado la velocidad y dirección del viento de la estación de referencia del parque eólico, la velocidad y dirección de una segunda estación ajena al parque eólico y los datos históricos de producción del parque eólico. La información disponible para cada una de las variables

son medias horarias. Los datos de la estación ajena al parque se corresponde con los de una de las siete estaciones meteorológicas adicionales utilizadas para la generación del modelo y que se describirán más adelante. En la capa de salida se tendrá la predicción a corto plazo de la potencia futura del parque eólico.

De cada una de las variables de la capa de entrada se ha utilizado la información del rango de tiempo que va desde t_i hasta t_{i-n} . Siendo t_i el instante en el que se predice y "n" el periodo de tiempos, anterior al del momento de predicción, escogido para la generación del modelo.

En la capa de salida se tendrá los valores estimados de la potencia del parque eólico para m-periodos de tiempo. Para este estudio cada periodo de tiempo equivale a una hora.

A partir del desarrollo metodológico explicado anteriormente se han generado los modelos de ANN para analizar los siguientes casos:

- Análisis de la influencia que tiene en la precisión del modelo, el número de periodos de tiempos, previo al momento de predicción, considerado para las diferentes variables que intervienen en la capa de entrada.
- Análisis de la influencia en la precisión del modelo, de la incorporación adicional de la información de una segunda estación meteorológica ajena al parque eólico.

Caso A) Influencia del número de periodos de tiempo de las variables de la capa de entrada

El horizonte temporal de predicción, m, podrá ser igual a 3,6,12,24 y 36 horas. En este caso A se estudiará, para cada uno de los horizontes temporales, la influencia que tiene en la precisión del modelo la variación del periodo de tiempos de las variables de la capa de entrada ("n"). n, al igual que m, podrá tomar los valores 3,6,12,24 y 36. Es decir, para cada horizonte temporal se generarán 5 modelos diferentes, según sea el valor de n, pudiendo comparar los resultados obtenidos para cada uno de ellos. Teniendo en cuenta los valores que puede tomar el horizonte temporal de predicción, m, el número total de modelos generados serán 25. En la figura 9.2 se muestra la estructura que tendría la red

neuronal para este caso A; Donde V_t , D_t y P_t , son la velocidad del viento, dirección del viento y la potencia del parque eólico, respectivamente. El número de neuronas de la capa oculta será fijo e igual a 20. Las neuronas de la capa de salida serán las potencias del parque eólico en los instantes posteriores al de predicción. El número de éstas dependerá del horizonte temporal de predicción y es por lo que fluctuará de 3 a 36 neuronas. Para el caso de la capa de entrada, el número de neuronas también será variable dependiendo del valor de "n"; pudiendo fluctuar de 9 neuronas ($n=3$) a 108 ($n=36$).

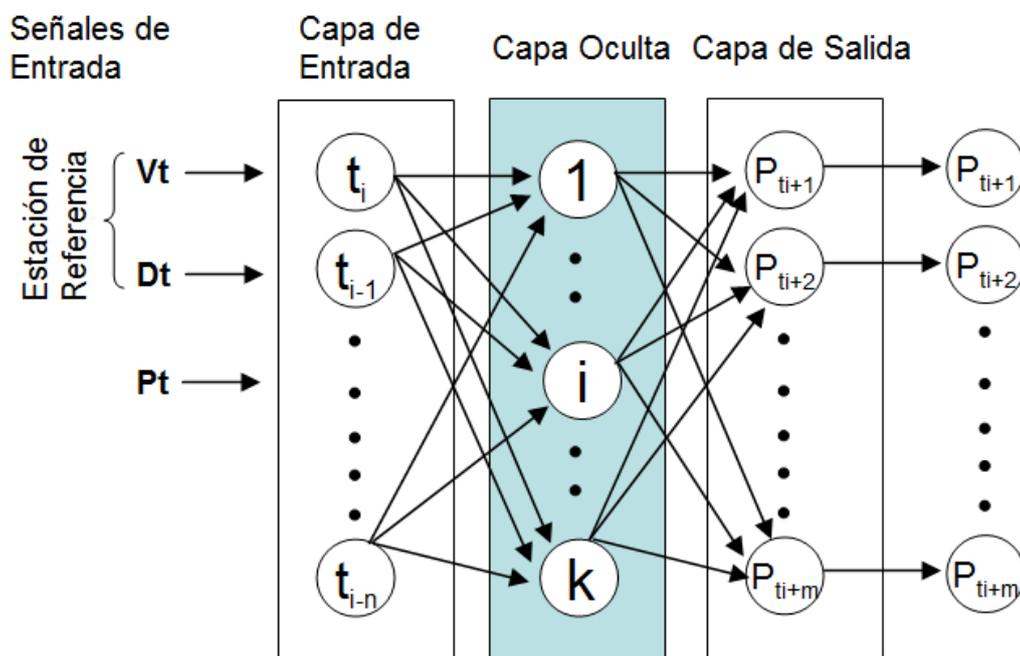


Figura 9.2: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso A).

Caso B) Influencia de la incorporación de la información de una estación meteorológica adicional

En este caso B el horizonte temporal de predicción podrá tomar los mismos valores indicados para el caso A). Para este caso, la capa de entrada de la ANN además de disponer de las variables descritas para el caso A, se le incorpora adicionalmente la información de velocidad y dirección del viento de una estación meteorológica ajena al parque eólico. Esta segunda estación meteorológica adicional se escoge de un total de siete de las que se dispone de información y que se describirán más adelante. Por lo

tanto, para este caso B se generarán 175 modelos diferentes (25 x 7), cuyos resultados serán comparados.

En la figura 9.3 se muestra la estructura que tendría la red neuronal para este caso B; Donde V_t , D_t y P_t , son la velocidad del viento, dirección del viento y la potencia del parque eólico, respectivamente. El número de neuronas de la capa oculta será fijo e igual a 20. Las neuronas de la capa de salida serán las potencias del parque eólico en los instantes posteriores al de predicción. El número de éstas dependerá del horizonte temporal de predicción y es por lo que fluctuará de 3 a 36 neuronas. Para el caso de la capa de entrada, el número de neuronas también será variable dependiendo del valor de "n"; pudiendo fluctuar de 15 neuronas ($n=3$) a 180 ($n=36$).

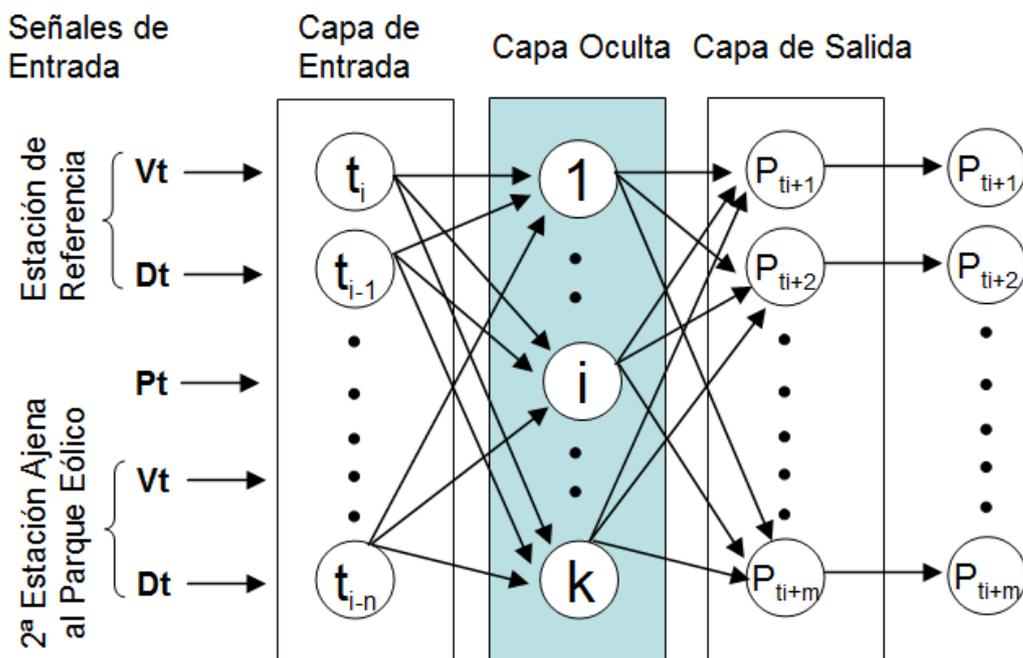


Figura 9.3: Esquema de la red neuronal para la generación de los modelos de predicción para el Caso B).

9.3.1 Métricas utilizadas para la comparación de los diferentes modelos.

Para poder comparar la precisión de los diferentes modelos generados tanto en el caso A como en el B, se han utilizado las siguientes métricas

$$\text{Ecuación 9.3 } MARE = \frac{1}{m} \sum_{j=1}^m \frac{1}{T} \sum_{r=1}^T \left(\frac{|P_{i+j} - O_{i+j}|}{P_{i+j}} \right)_r = \frac{1}{m} mare_{i+j}$$

Donde:

MARE, es el error medio relativo en el horizonte temporal de predicción

i , es el instante de tiempo en el que se predice

$P_{i+j,r}$, es el valor real de la potencia del parque eólico en el instante de tiempo "i+j"

$O_{i+j,r}$, es el valor estimado para la potencia del parque eólico en el instante de tiempo "i+j"

T_r , es el número de datos de la fase Test (figura 9.1)

m , es el número de periodos del horizonte temporal que se predice

$mare_{i+j}$, es el error relativo medio para el instante de predicción "i+j"

$$\text{Ecuación 9.4 } R = \frac{1}{m} \sum_{j=1}^m \frac{\sum_{r=1}^T (P_{(i+j)_r} - \overline{P_{i+j}}) \times (O_{(i+j)_r} - \overline{O_{i+j}})}{\sqrt{\left[\sum_{r=1}^T (P_{(i+j)_r} - \overline{P_{i+j}})^2 \right] \times \left[\sum_{r=1}^T (O_{(i+j)_r} - \overline{O_{i+j}})^2 \right]}} = \frac{1}{m} \sum_{j=1}^m R_{i+j}$$

Donde:

R , es el coeficiente de correlación medio entre los valores reales y estimados de la potencia del parque eólico en el horizonte temporal de predicción

R_{i+j} , es el coeficiente de correlación entre los valores reales y estimados de la potencia para el instante de predicción "i+j"

i , es el instante de tiempo en el que se predice

P_{i+j} , es el valor real de la potencia del parque eólico en el instante de tiempo "i+j"

O_{i+j} , es el valor estimado para la potencia del parque eólico en el instante de tiempo "i+j"

T_r , es el número de datos de la fase Test (figura 9.1)

m , es el número de periodos del horizonte temporal que se predice

R_{i+j} , es el coeficiente de correlación entre los valores reales y estimados de la potencia para el instante de predicción "i+j"

9.4 Datos de Partida

Para el estudio realizado en el presente capítulo se han utilizado los datos correspondientes a un Parque eólico ubicado en el T.M. de Ingenio al sudeste de la isla de Gran Canaria. El parque eólico está constituido por cuatro aerogeneradores de la marca Gamesa G47 de 660 kW cada uno (Fig 9.4). Se dispone de la información de las producciones horarias para el año 2008. El rendimiento energético del parque eólico durante el año en cuestión fue de 3.645 MWh/MW.



Figura 9.4: Distribución en planta del parque eólico

Adicionalmente, para el estudio planteado como Caso B, se ha utilizado la información de siete (7) estaciones meteorológicas adicionales. Estas estaciones se encuentran ubicadas en cuatro islas diferentes del archipiélago canario. De éstas se dispone de los datos medios horarios de la velocidad y dirección del viento. La información ha sido cedida por el Instituto Tecnológico de Canarias (ITC), empresa pública perteneciente al Gobierno de Canarias.

En la figura 9.5 se muestra la ubicación tanto de las estaciones (WS) utilizadas así como la del parque eólico (WF1). WS-1 es la estación meteorológica de referencia del parque eólico.

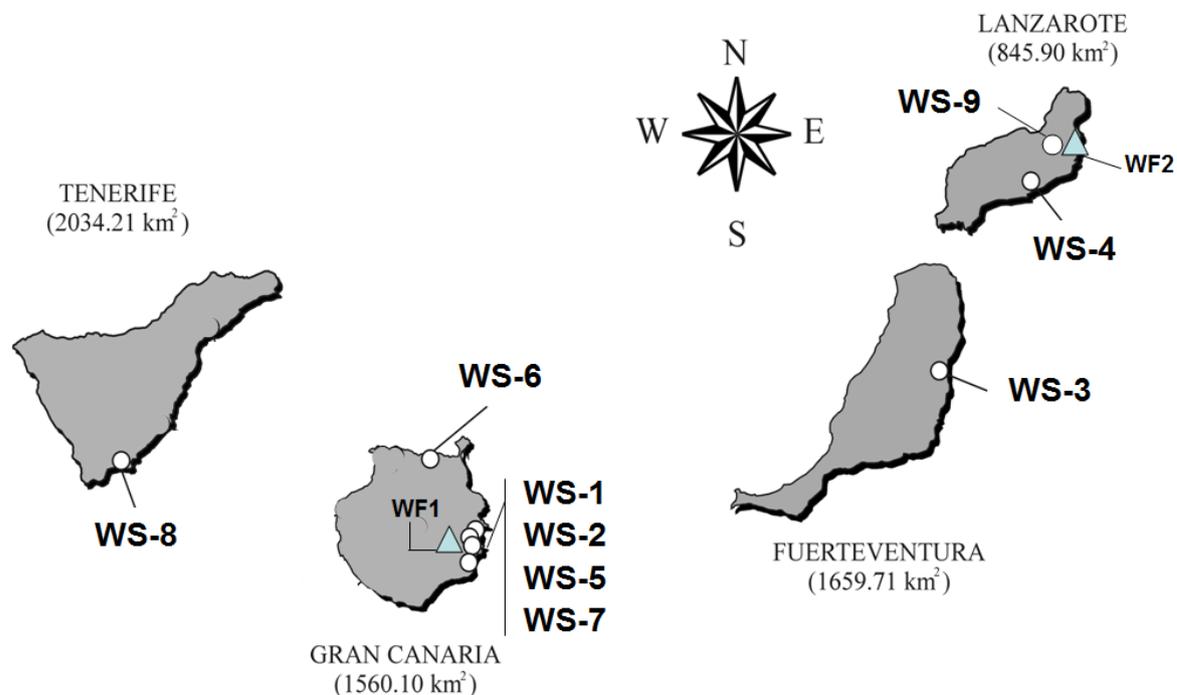


Figura 9.5: Ubicación de las estaciones anemométricas (WS) y del parque eólico (WF).

En la tabla 9.1 se reflejan algunos datos de interés de cada una de las estaciones utilizadas en el estudio.

Tabla 9.1: Información de las estaciones meteorológicas utilizadas en el estudio.

Código (WS)	Altura (m)	Latitud (N)	Longitud (W)	Altitud (m)	Velocidad media anual (m/s)
WS-1	40	27°54'08"	15°23'17"	16	8,8
WS-2	10	27°51'36"	15°23'13"	3	7,7
WS-3	10	28°27'10"	13°51'54"	24	5,6
WS-4	10	28°57'7"	13°36'	10	5,4
WS-5	13	28°01'36"	15°23'16"	5	6,9
WS-6	10	28°07'30"	15°40'37"	472	8,5
WS-7	10	27°56'08"	15°25'24"	186	6
WS-8	10	28°02'35"	16°34'16"	51	6

En la Tabla 9.2 se reflejan los coeficientes de correlación lineal entre las velocidades medias horarias del viento de las diversas estaciones utilizadas, Ecuación 9.5.

Ecuación 9.5

$$CC = \frac{\sum_{i=1}^{NG} (V_i - \bar{V}) \times (V'_i - \bar{V}')}{\sqrt{\sum_{i=1}^{NG} (V_i - \bar{V})^2} \times \sqrt{\sum_{i=1}^{NG} (V'_i - \bar{V}')^2}}$$

Donde:

CC, es el coeficiente de correlación de las velocidades de dos de las estaciones empleadas en el estudio.

NG, es el número total de datos de la serie disponible. En este caso, al ser la serie igual a un año y los datos ser medias horarias, NG es igual a 8760.

V_i y V'_i , son las velocidades en el instante i de las dos estaciones a correlacionar.

\bar{V} y \bar{V}' , son las velocidades medias de ambas estaciones para toda la serie de datos.

Tabla 9.2: Coeficiente de Correlación Lineal entre las velocidades de las diferentes estaciones meteorológicas. Año 2008

	WS-1	WS-2	WS-3	WS-4	WS-5	WS-6	WS-7	WS-8
WS-1	1,000	0,841	0,275	0,343	0,745	0,736	0,775	0,503
WS-2	0,841	1,000	0,192	0,251	0,790	0,744	0,871	0,444
WS-3	0,275	0,192	1,000	0,702	0,166	0,162	0,181	0,161
WS-4	0,343	0,251	0,702	1,000	0,209	0,215	0,227	0,201
WS-5	0,745	0,790	0,166	0,209	1,000	0,493	0,780	0,218
WS-6	0,736	0,744	0,162	0,215	0,493	1,000	0,610	0,621
WS-7	0,775	0,871	0,181	0,227	0,780	0,610	1,000	0,397
WS-8	0,503	0,444	0,161	0,201	0,218	0,621	0,397	1,000

9.5 Arquitectura de las Redes Neuronales utilizadas.

Las ANN utilizadas en este capítulo han consistido en redes de tres capas con conexiones hacia delante (feedforward). Concretamente se han usado topologías multilayer perceptrons (MLPs) [Capítulo8; refs. 6-7]. 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 [Capítulo8; refs. 6-7] y ha sido propuesta por diversos autores [Capítulo8; refs. 17, 22, 21]. 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.

Las arquitecturas diseñadas han sido entrenadas usando el algoritmo de Backpropagation con función de activación sigmoideal [Capítulo8; refs. 6-7]. Como algoritmo de minimización del error cuadrático medio cometido en el aprendizaje se ha utilizado el de Levenberg-Marquard [Capítulo8; refs. 18, 6].

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 o test [3] (figura 9.1). La proporción de datos seleccionada para cada una de los procesos ha sido de 70%,15% y 15%, respectivamente.

El subconjunto de datos de entrenamiento se utiliza para la estimación de los pesos de la ANN. El subconjunto de validación es utilizado para chequear el progreso del entrenamiento de las ANN, optimizando los parámetros de las mismas. Es decir, se utilizan para medir el grado de generalización de las ANN. El subconjunto de los datos de ensayo o test, que no han sido utilizados ni en la etapa de entrenamiento ni de validación, es usado para determinar la fiabilidad del modelo generado en las fases de entrenamiento y validación. Es decir, constituye una medida independiente del funcionamiento de la red.

Los distintos experimentos han sido realizados empleando las herramientas que para las redes neuronales presenta el software informático Matlab. Los requisitos mínimos de memoria RAM para la generación de todos los modelos fue de 16MB.

9.6 DISCUSION DE LOS RESULTADOS OBTENIDOS

La discusión de los resultados se ha realizado en base a los dos casos planteados en la metodología. En las diferentes figuras, "t" simboliza el periodo de tiempo en el que se predice. En este sentido, "t-3" indicaría que se ha escogido 3 periodos de tiempo previos al de predicción, incluido éste. Por el contrario, "t+3" indicaría que se trata del caso de un horizonte temporal de predicción de 3 periodos, contados a partir del que se predice.

Discusión de los resultados para el caso A): Influencia del número de periodos de tiempo de las variables de la capa de entrada

En las figuras 9.6 y 9.7, se observa que los valores del MARE y R, respectivamente mejoran, para el caso particular de cada horizonte temporal, a medida que se aumenta el número de periodos previos al de predicción que se escogen para las variable de la capas de entrada. Esta mejora es más importante cuanto mayor es el horizonte temporal de predicción. La mejora en los resultados del se producen hasta el caso t-24. Para el caso t-36 la mejora es mínima o simplemente no se observa mejora en el modelo.

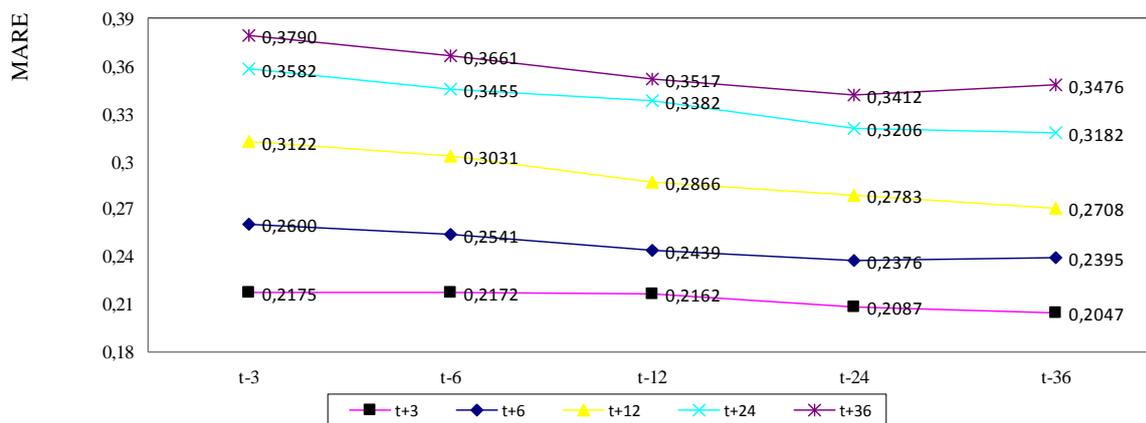


Figura 9.6: MARE para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

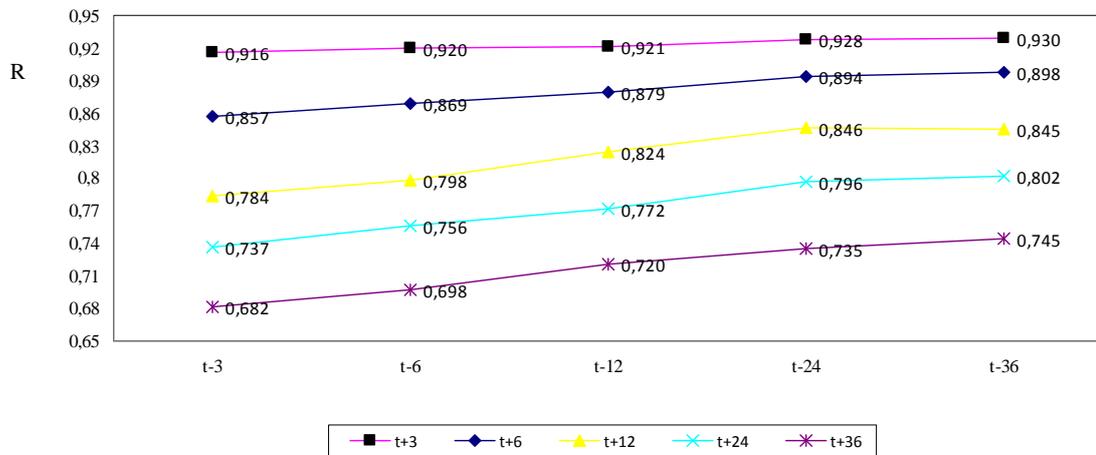


Figura 9.7: Valor de R para los diferentes modelos según sea el horizonte temporal de predicción y el número de periodos elegidos para las variables de la capa de entrada a la ANN

Para el caso del MARE y para los horizontes temporales t+12, t+24, t+36, se observa que el modelo mejora en un 13,3%, 11,2% y 8,3%, respectivamente. Para los mismos casos pero para la "R", las mejoras son del 7,8%, 8,8% y 9,2%, respectivamente.

La figura 9.8 muestra la variación del MARE en los diferentes periodos de predicción y para el caso particular de un horizonte temporal de 24 periodos (t+24). En ésta se han diferenciado los resultados según sea el número de periodos, previos al de predicción, escogidos para las variables de la capa de entrada. Se observa que, cuanto mayor sea el número de periodos previos escogidos, el MARE a medida que avanza el periodo de predicción, además de ser claramente inferior, se mantiene más estable dentro del horizonte temporal de predicción.

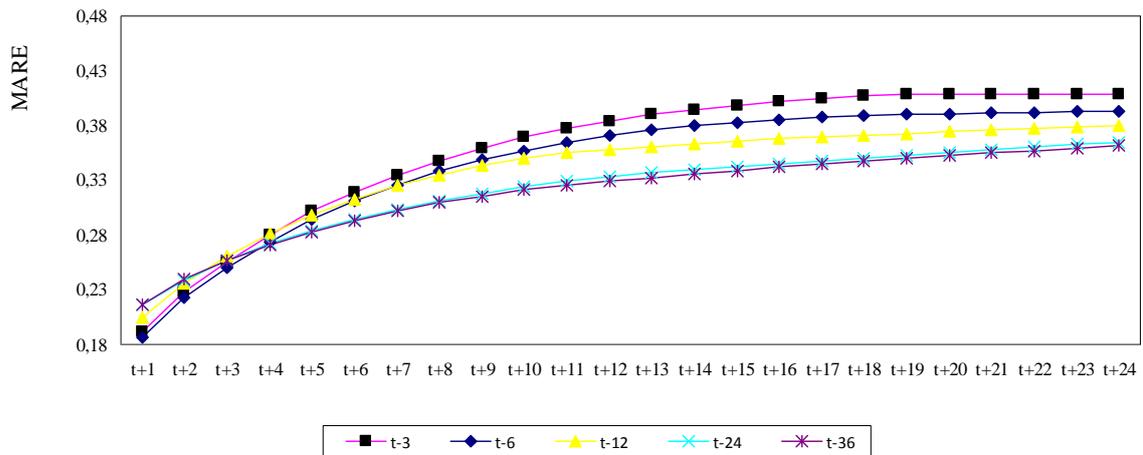


Figura 9.8: Variación del MARE para los diferentes periodos de predicción. Caso de un horizonte temporal t+24

El análisis realizado con la figura 9.8 para el caso particular de un horizonte temporal t+24 (figura 8), se ha reflejado en la figura 9.9 para todos los horizontes temporal de predicción estudiados. En ésta, se observa como la desviación típica relativa del MARE, Ecuación 9.6, para todos los horizontes temporales de predicción, disminuye generalmente cuando se aumenta el número de periodos, previos al de predicción, escogidos en las variables de entrada. Solamente para el caso particular de un horizonte t+3 y cuando se pasa de t-24 a t-36 esta reducción no se aprecia.

$$\text{Ecuación (9.6)} \quad Desv = \frac{1}{T} \sum_{r=1}^T \sqrt{\frac{\sum_{j=1}^m (mare_{(i+j)_r} - \overline{mare_r})^2}{m-1}}$$

Donde:

Desv, es la desviación típica media del MARE para un horizonte temporal de predicción "m"

m, es el número de periodos del horizonte temporal que se predice

i, es el instante de tiempo en el que se predice

T, es el número de datos de la fase Test (figura 9.1)

mare_(i+j), es el error relativo para el instante de predicción "i+j"

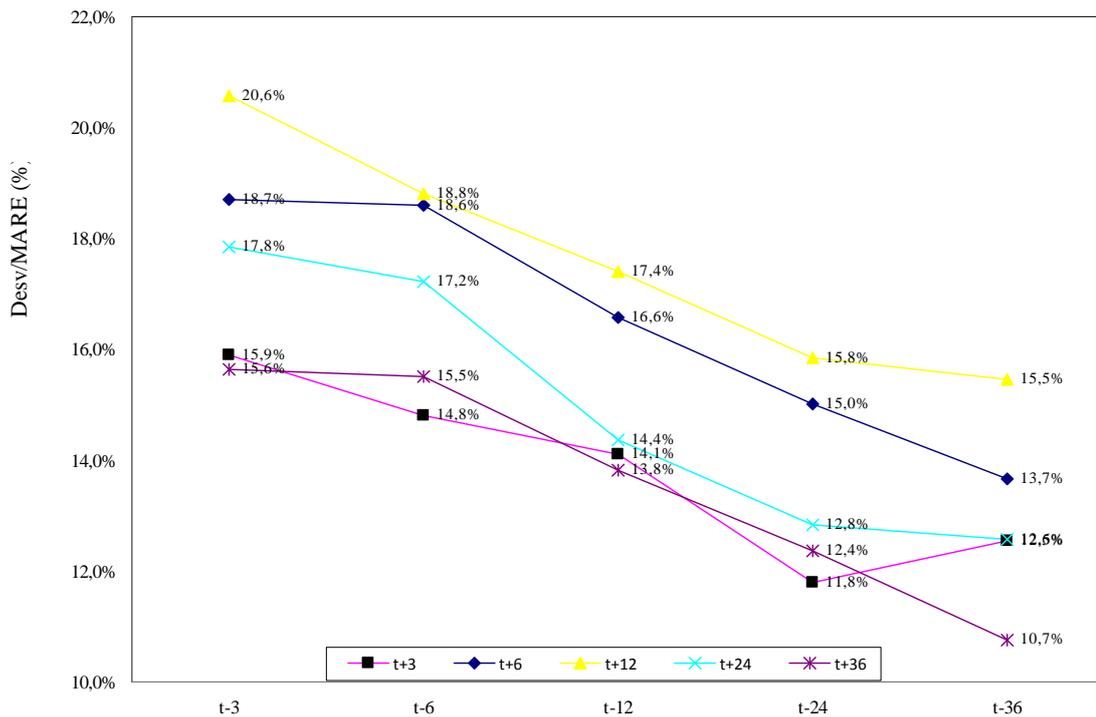


Figura 9.9: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN

En el capítulo 7 se explicó el proceso mediante el cual se penalizaba económicamente a las instalaciones de generación de energía eléctrica por el desvío en la predicción de su producción de energía eléctrica en el mercado eléctrico (Coste de Desvío). Para el estudio realizado en el presente capítulo se ha valorado cómo influyen las mejoras aportadas por los nuevos modelos de ANN desarrollados en la penalización económica por el desvío, así como en su equivalencia en las pérdidas del rendimiento energético del parque eólico concreto estudiado en este capítulo. Para ello, a partir de la información de los costes desvíos horarios por MWh establecidos para el año 2008 [19] y siguiendo el proceso ya descrito en el punto 7.3, se calculó el coste de desvío medio específico en €/MWh (Cd_e).

Teniendo en cuenta los resultados obtenidos para las fiabilidades de los diferentes modelos (Figuras 9.6 y 9.7), para un horizonte temporal de predicción determinado la penalización económica al desvío disminuye a medida que se escoge, para la generación del modelo de ANN, un mayor número de periodos de tiempos previos al de predicción. Así por ejemplo, para un el horizonte temporal de predicción de 24 horas, la penalización económica por el desvío, para el parque eólico de estudio, disminuye desde los 44.150,4€ para el modelo "t-3" hasta 38.719,2 para el modelo "t-36", es decir en 5.431,2€/año (12,3%). Hay que tener en cuenta que el valor absoluto del ahorro económico sería tanto mayor cuanto mayor sea la dimensión del parque eólico. En este caso se ha trabajado con un parque eólico de dimensiones relativamente pequeñas (2,64MW). Si por ejemplo se tomara como referencia los 440 MW aprobados por el gobierno de Canarias en el último concurso de asignación de potencia eólica [20], y partiendo de la hipótesis que la fiabilidad de los modelos se comporten de forma similar al del estudio realizado en el presente capítulo, el ahorro económico llegaría ser de 905.200€/año.

En el capítulo 7 se hizo además una valoración de la penalización económica por el desvío en términos de pérdidas en el rendimiento energético del parque eólico (Ecuaciones 20 y 21). Dicha valoración se ha realizado en el presente capítulo al parque eólico en cuestión. En primer lugar, a partir de la información de los precios medios horarios de la energía en el mercado eléctrico español para el año 2008 [21], y siguiendo un procedimiento similar al explicado en el punto 7.5.3, se estimó la producción del precio medio ponderado de la energía para ese año en €/MWh (Pr_e). Para ello, en este caso, se utilizó la distribución de la generación energética real del parque eólico en lugar de la del viento.

Una vez calculados los valores para Cd_e y Pr_e y a partir de la información real del rendimiento energético del parque eólico para el año 2008, la equivalencia del coste económico del desvío en pérdidas del rendimiento energético del parque eólico, Ecuación 9.7.

$$\text{Ecuación 9.7 } VarEP = EP \times \left(\frac{Cd_e}{Pr_e} \right)$$

Donde:

VarEP, es la reducción equivalente en el rendimiento energético del parque eólico por la penalización económica al desvío (en MWh/MW).

EP, es el rendimiento energético real del parque eólico (en MWh/MW)

Cd_e , Coste de desvío específico (en €/MWh_{generados})

Pr_e , es el precio medio específico de la energía eléctrica (en €/MWh)

En la figura 9.10 se observa la reducción equivalente en el rendimiento energético del parque eólico estudiado en este capítulo por la penalización económica al desvío, para los diferentes modelos de ANN estudiados en el caso A). Se observa que las pérdidas equivalentes en el rendimiento energético pueden llegar a ser de hasta 309,8 MWh/MW, pudiendo ésta disminuirse hasta las 282,9 (-8,7%) si se utilizan más periodos de tiempos, previos al de predicción, en las variables de la capa de entrada de la ANN.

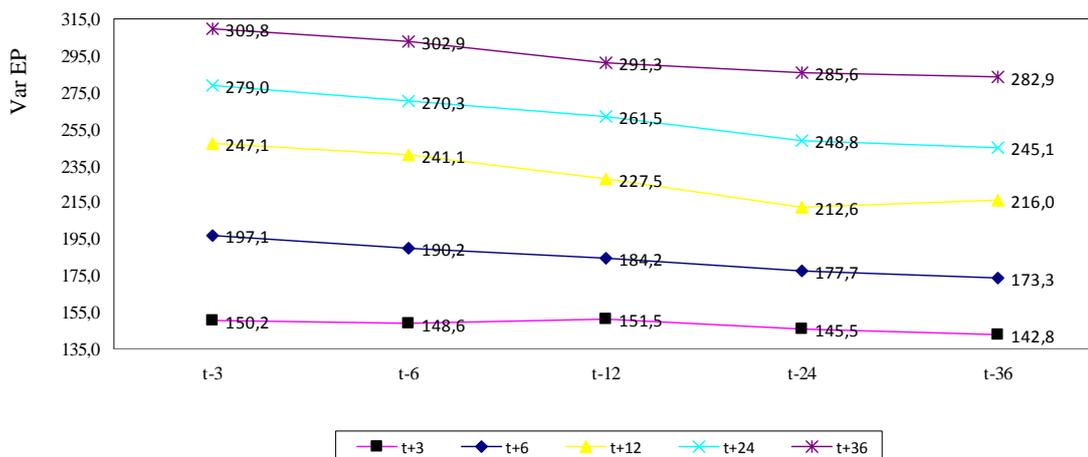


Figura 9.10: Desviación típica relativa del MARE para los diferentes horizontes temporales de predicción, según sea el número de periodos previos escogidos para las variables de la capa de entrada de la ANN.

Discusión de los resultados para el caso B): Influencia de la incorporación de la información de una estación meteorológica adicional

En este análisis se ha estudiado la influencia que tiene la incorporación de la información meteorológica (velocidad y dirección del viento) de una estación adicional ajena a la de referencia del parque eólico. Se han implementado los nuevos modelos de ANN para cada

uno de los horizontes temporales de predicción (+3,+6,+12,+24 y +36 horas) y para cada número de periodos previos al de predicción (-3,-6,-12,-24 y -36 horas) combinando, junto con la estación de referencia del parque, cada una de las otras siete (7) estaciones ajenas a éste. Como se comentó en el punto 9.3 para el caso de estudio B), el número de modelos obtenidos fue de 175 (35 para cada uno de los horizontes temporales de predicción).

Se compararon las fiabilidades, a través de los parámetros MARE y R, de los modelos resultantes con los obtenidos para los casos de una sola estación. Los resultados se muestran en las figuras 9.11 y 9.12.

Se comprobó que en el 76% de los 175 modelos obtenidos se mejoraron los resultados del caso de una sola estación. Aún así, para todos los horizontes temporales de predicción siempre se encontró una estación adicional, ajena a la del parque, cuya incorporación a la capa de entrada de la ANN mejoraba los resultados obtenidos para una sola estación.

En la figura 9.11 se refleja el mejor de los resultados para la variación relativa experimentada por el MARE (Δ MARE) del modelo al incorporar a la ANN la nueva estación, ecuación 9.8.

$$\text{Ecuación 9.8 } \Delta \text{ MARE} = \frac{\text{MARE}_{2 \text{ estaciones}} - \text{MARE}_{1 \text{ estación}}}{\text{MARE}_{1 \text{ estación}}}$$

En términos generales se observó que la mejora del MARE, al incorporar una estación adicional, era más importante cuanto mayor fuera el horizonte temporal de predicción. Esta observación es válida hasta un horizonte de predicción de 24 horas, a partir de éste, si bien el MARE mejoraba, no seguía la tendencia explicada anteriormente. Las mejoras del MARE del modelo alcanzaban en algunos casos valores superiores al 7,5%.

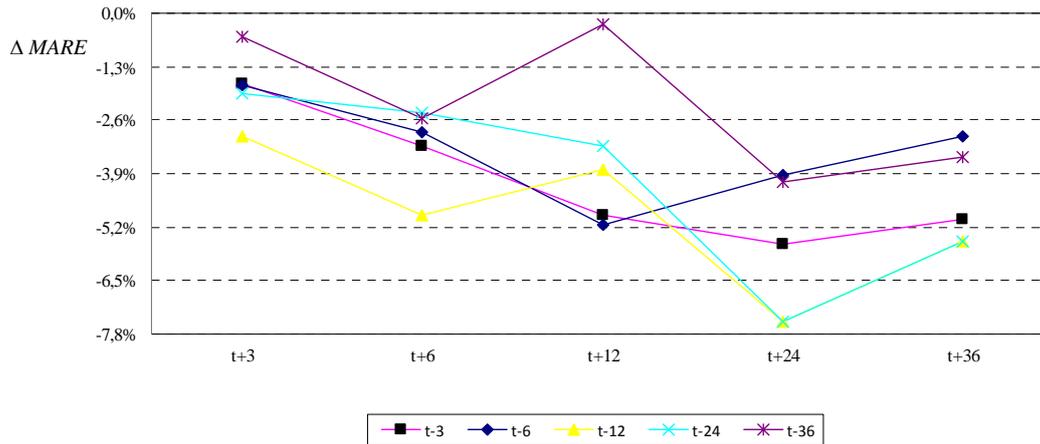


Figura 9.11: Mejora experimentada por el MARE del modelo al incorporar una estación adicional a la capa de entrada de la ANN

En la figura 9.12 se muestran los resultados obtenidos para la variación del coeficiente de correlación del modelo, Ecuación 9.9.

$$\text{Ecuación 9.9 } \Delta R = \frac{R_{2 \text{ estaciones}} - R_{1 \text{ estación}}}{R_{1 \text{ estación}}}$$

Al igual que para el MARE se observó que, en términos generales, la mejora era más importante cuanto mayor fuera el horizonte temporal de predicción, llegando a ser ésta hasta del 5,3%.

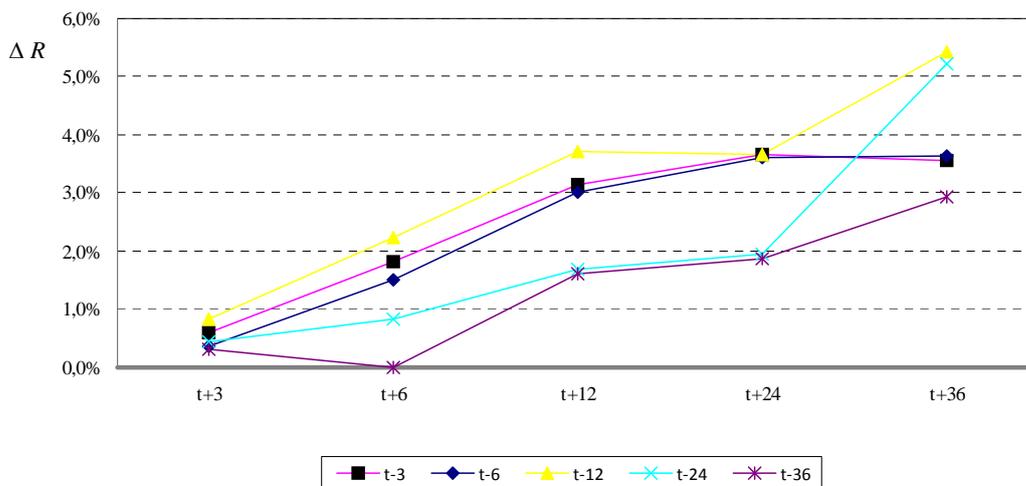


Figura 9.12: Mejora experimentada por el R del modelo al incorporar una estación adicional a la capa de entrada de la ANN.

9.7 CONCLUSIONES AL CAPÍTULO

En el presente capítulo se ha mostrado el estudio de investigación en el que se ha desarrollado, aplicando las redes neuronales artificiales, diferentes modelos para la predicción de la potencia eléctrica generada para un parque eólico. Éstos se han aplicado a un parque real ubicado en el sudeste de la isla de Gran Canaria. Se ha analizado la influencia que tiene en la precisión del modelo aspectos como el número de periodos (en el presente estudio un periodo equivale a una hora), previos al de predicción, que se escogen para las variables de la capa de entrada de la ANN así como la incorporación en dicha capa de los datos meteorológicos (velocidad y dirección del viento) de una estación anemométrica adicional, ajena a la propia del parque eólico.

Como conclusiones, destacar las siguientes:

- Para un número de periodos, previos al de predicción, de hasta 24 horas, se observó que al aumentar éstos siempre se mejoraron los resultados obtenidos para los modelos, independientemente del horizonte temporal de predicción. A partir de 24 horas previas, generalmente el modelo podía mejorar pero de forma insignificante.
- El grado de mejora es más importante cuando el horizonte temporal de predicción es igual o superior a 12 horas.
- Para los casos particulares de horizontes temporales $t+12$, $t+24$, $t+36$, se observó que el modelo podía mejorar el MARE en un 13,2%, 11,2% y 8,3%, respectivamente y la R en un 7,8%, 8,8% y 9,2%, respectivamente.
- Con el aumento del número de periodos, previos al de predicción, en las variables de la capa de entrada se conseguía además estabilizar más rápidamente el error de los diferentes periodos dentro de un horizonte temporal dado, Figuras 9.8 y 9.9
- Para el parque eólico analizado en el presente capítulo la mejora en la predicción, al aumentar el número de periodos previos en las variables de la capa de entrada, podría suponer un ahorro en la penalizaciones económicas por el desvío en el mercado eléctrico del 12,3%, equivalentes a 5.431,2€/año.
- La incorporación de la información meteorológica de una estación adicional, ajena a la de referencia del parque eólico, a la capa de entrada de la ANN mejoró la precisión en el 76% de los 175 modelos generados en el "caso B". Aún así, al

- disponer de siete estaciones que se podían combinar como adicionales, para los 25 modelos desarrollados en el "caso A", siempre se encontró para éstos una que al incorporarla mejoraba los resultados obtenidos.
- Estaciones que se podían combinar como adicionales, para todos los modelos desarrollados en el caso A) siempre se encontró una que, al incorporarla, mejoraba los resultados obtenidos.
- La mejora que experimentaron los modelos al incorporar la segunda estación era tanto mayor cuanto mayor fuere el horizonte temporal de predicción, figura 9.11, pudiendo llegar el MARE a mejorar en un 9,5% y la R en un 5,3%.

9.8 REFERENCIAS:

- [1] Red Eléctrica de España. El sistema eléctrico español. Avance del informe. 2014 http://www.ree.es/sites/default/files/downloadable/avance_informe_sistema_electrico_2014b.pdf (último acceso 17/09/2015).
- [2] Parlamento Europeo y del Consejo. Directiva 2009/28/CE de 23 de abril de 2009 relativa al fomento del uso de energía procedente de fuentes renovables . Diario oficial de la Unión Europea. 2009: pp L140/16 L149/62
- [3]Gobierno de Canarias. Plan Energético de Canarias. <http://www.gobiernodecanarias.org/energia/doc/planificacion/pecan/pecan2007.pdf>. Año 2007. (último acceso 17/09/2015).
- [4]Gobierno de Canarias. Revisión del Plan Energético de Canarias. <http://www.gobiernodecanarias.org/energia/doc/planificacion/pecan/pecan2007.pdf>. Año 2012 (último acceso 17/09/2015).
- [5] Justus CG, Mani K, Mikhail AS. Interannual and month-to-month variations of wind speed. Journal of Applied Meteorology 1979; 18:913–20.
- [6] 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.
- [7] Klink K. Trends and interannual variability of wind speed distributions in Minnesota. J. Clim. 2002; 15: 3311-7.
- [8] Foley A, Leahy P, Marvuglia A, McKeogh E. Current methods and advances in forecasting of wind power generation. Renew Energy Jul. 2012;37:1e8.
- [9] Amjady N, Keynia F, Zareipour H. Short-term wind power forecasting using ridgelet neural network. Electr Power Syst Res Sept. 2011;81:2099e107.
- [10] Khalid M, Savkin A. A method for short-term wind power prediction with multiple observation points. IEEE Trans Power Syst May 2012;27:579e86
- [11] Adel Brkaa, Yasir M. Al-Abdelia & Ganesh Kothapallia a School of Engineering, Edith Cowan University, Joondalup, WA6027, Australia Published online: 21 Jan 2014.
- [12] Cali, U., B. Lange, J. Dobschinski, M. Kurt, C. Möhrlein, and B. Ernst. 2008. "Artificial Neural Network Based Wind Power Forecasting Using aMulti-Model Approach." 7th InternationalWorkshop on Large Scale Integration ofWind Power and on Transmission Networks for OffshoreWind Farms, 1–6. Madrid, Spain.

- [13] Bhaskar, K., and S. Singh. 2012. "Awnn-AssistedWind Power Forecasting Using Feed-Forward Neural Network." IEEE Transactions on Sustainable Energy 3 (2): 306–315.
- [14] Forecasting aggregated wind power production of multiple wind farms using hybrid wavelet-PSO-NNs Paras Mandal¹, Hamidreza Zareipour² and William D. Rosehart²
¹Department of Industrial, Manufacturing and Systems Engineering, University of Texas at El Paso, El Paso, TX 79968, USA
²Department of Electrical and Computer Engineering, University of Calgary, Calgary, Alberta T2N 1N4, Canada
- [15] Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information G.J. Os_orio^a, J.C.O. Matias^a, J.P.S. Catalao^{a,b,c}.
a University of Beira Interior, R. Fonte do Lameiro, 6201-001 Covilha, Portugal
b INESC-ID, R. Alves Redol, 9, 1000-029 Lisbon, Portugal
c IST, University of Lisbon, Av. Rovisco Pais, 1, 1049-001 Lisbon, Portugal
- [16] A review of combined approaches for prediction of short-term wind Speedy and power A.Tascikaraoglu n, M.Uzunoglu Department of Electrical Engineering, Yildiz Technical University, Istanbul 34220, Turkey
- [17] El-Fouly THM, El-Saadany EF, Salama MMA. One day ahead prediction of wind Speedy and direction. IEEE Trans Energy Convers 2008; 23:191–201.
- [18] Short-Term Wind Power Ensemble prediction Based on Gaussian Processes and Neural Networks. Duehee Lee, Student Member, IEEE, and Ross Baldick, Fellow, IEEE.
- [19] Red Eléctrica de España (REE). <http://www.esios.ree.es/web-publica> Click en "MIBEL",
"Desvíos medidos" y "costes de desvíos RD 661/2007".
- [20] Gobierno de canarias. 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, 89. 2007. pp: 9315-9353
- [21] Operador del Mercado Eléctrico (OMEL). Información del Mercado. www.omie.es/inicio. 2014.

CAPITULO 10

**Conclusiones de la tesis y Líneas de
Investigación Futuras que se Proponen**

INDICE

10 Conclusiones de la Tesis y líneas de investigación futuras que se proponen.....	307
10.1 Introducción.....	307
10.2 Aportaciones de la tesis.....	308
10.3 Conclusiones.....	310
10.4 Líneas de investigación futuras que se proponen.....	313

10 CONCLUSIONES DE LA TESIS Y LINEAS DE INVESTIGACION FUTURAS QUE SE PROPONEN

10.1 Introducción

En el presente trabajo de investigación se ha querido dar solución a un problema a partir de la idea que se resume a continuación:

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 1.2), 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.

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 (Figura 2.17). En concreto para el caso de la energía eólica se pretende tener instalados 1025 MW en el año 2020. A finales del 2014 la potencia eólica instalada en el archipiélago canario era de 154MW

La capacidad de maximizar la contribución de la energía eólica, como fuente de generación de energía eléctrica no gestionable, a la demanda así como su integración en los mercados eléctricos, depende en gran medida del grado de predicción de la misma. Este hecho se hace aún más importante cuando se trata de sistemas eléctricos insulares débiles, como son los que se encuentran en el archipiélago canario, donde cada isla posee su propio sistema eléctrico insular aislado del resto de éstas y del sistema eléctrico peninsular.

En la literatura científica se han propuesto diferentes métodos para la predicción de la potencia eléctrica de origen eólico utilizando diversas técnicas para la generación de los modelos.

En el presente trabajo de investigación se han desarrollado modelos para la predicción a corto plazo de la potencia eléctrica de parques eólicos utilizando las redes neuronales artificiales. Para ello se ha utilizado la información de parques eólicos reales ubicados en el archipiélago canario. Se han estudiado las mejoras obtenidas en la precisión de los

modelos según sea la información que se escoja en las variables de la capa de entrada de la red neuronal y se ha valorado económicamente dichas mejoras por la reducción de la penalización económica debida al desvío en la predicción.

Por otro lado, se ha desarrollado un modelo dinámico de curva de potencia global de parque eólico empleando las redes neuronales artificiales. Éste se ha comparado con la propia curva de potencia del aerogenerador (modelo estático) para analizar las mejoras del primero sobre éste. El modelo dinámico de curva de potencia desarrollado, al referirse al parque eólico completo y no al de un aerogenerador concreto, ya contempla internamente aspectos como las pérdidas energéticas por la rugosidad del terreno, las pérdidas energéticas debidas a las estelas entre aerogeneradores y la variación en la producción debido a la dirección en el que el viento incide sobre el parque eólico.

10.2 Aportaciones de la tesis

A continuación se expone un listado de las distintas aportaciones de los trabajos desarrollados en la presente tesis:

- Los modelos desarrollados se han aplicado a parques eólicos concretos situados en el archipiélago canario. Es en éste donde al encontrarse sistemas eléctricos aislados, el problema de la integración de fuentes de generación no gestionables es mayor.
Se ha utilizado la información aportada por los propietarios de dos parques eólicos ubicados en las islas de Gran Canaria y Lanzarote. Además se ha utilizado información meteorológica fiable, aportada por el Instituto Tecnológico de Canarias, empresa adscrita al Gobierno de Canarias y de reconocido prestigio en la gestión de información meteorológica.
- Se ha desarrollado un modelo dinámico de curva de potencia global del parque eólico a partir de la información histórica de éste y utilizando las redes neuronales artificiales. Se han comparado los resultados obtenidos aplicando el modelo desarrollado con los de la curva de potencia teórica (modelo estático) del aerogenerador.

- Se ha realizado en un mismo estudio un análisis de predicción a corto plazo para diferentes horizontes temporales. Pudiendo compararse los errores según sean éstos.
- Se ha analizado, para un horizonte temporal concreto, las mejoras que se obtiene en la fiabilidad del modelo, según el número de periodos (en este estudio un periodo es equivalente a una hora), previos al de predicción, que se escojan para las variables de la capa de entrada de la red neuronal. En el estudio realizado en la presente tesis las variables de entrada son: velocidad del viento, dirección del viento y producción histórica del parque eólico.

Los horizontes temporales de predicción que se han estudiado pueden ser de 3,6,12,24 y 36 horas ($t+3$; $t+6$; ...; $t+36$, siendo "t" el instante en el que se predice). De igual forma el número de periodos de tiempos previos al de predicción podrá tomar los valores 3,6,12,24 y 36 ($t-3$; $t-6$; ...; $t-36$, siendo "t" el instante en el que se predice). Es decir, para cada horizonte temporal se generarán 5 modelos diferentes, pudiendo compararse los resultados obtenidos para cada uno de ellos. Teniendo en cuenta los valores que puede tomar el horizonte temporal de predicción, el número total de modelos generados serán 25. Se trata de un número de modelos considerable para poder generalizar los resultados de este estudio.

- Se han analizado las mejoras que se obtiene en la precisión del modelo cuando se incorpora, a la capa de entrada de la red neuronal, la información meteorológica (velocidad y dirección del viento) de una estación adicional ajena a la propia del parque eólico.

Para ello se ha trabajado con información de 7 estaciones meteorológicas adicionales que se han combinado con los 25 modelos generados para una sola estación, por lo tanto en este caso se ha trabajado con 175 (25 x 7) modelos de red neuronal a partir de los que se han discutido los resultados.

- Los errores en la predicción de la potencia eléctrica generan como consecuencia penalizaciones en el mercado eléctrico (costes de desvío). Estas penalizaciones dependen, entre otras cosas, de la magnitud del error. En el trabajo desarrollado se han cuantificado no sólo las mejoras que se obtienen en la precisión de los diferentes modelos sino su implicación económica al disminuir las penalizaciones.

10.3 Conclusiones

En este apartado del capítulo se exponen las conclusiones más destacadas que se han obtenido.

- Los desvíos entre los valores predichos de la producción de energía eléctrica y los reales medidos, para una demanda de energía establecida, provocan alteraciones al sistema eléctrico cuya solución supone un coste económico adicional al mismo. Este coste económico es imputado proporcionalmente a las fuente de generación que provocan el desvío.
- De los resultados obtenidos en el estudio realizado en el capítulo 7, se propone que el coste económico específico imputado a un parque eólico debido a la desviación en la predicción (C_{de}), sea considerado como un factor adicional en su estructura de coste de producción de la energía eléctrica. Su contribución al coste total depende del error en la predicción, pudiendo llegar a ser del 15,5% para un error de predicción (NMAE) del 60%.
- Los modelos dinámicos de curva de potencia de parque eólico desarrollado utilizando las ANN's (Capítulo 8) mejoraron, para los dos parques eólicos en estudio, los resultados obtenidos utilizando el modelo estático de curva de potencia de aerogenerador.
- El grado de mejora en la precisión del modelo dinámico con respecto al estático fue tanto mayor cuanto mayor era la complejidad en la distribución de los aerogeneradores sobre el terreno. Para el caso del WF-1 el error del modelo, MARE, se redujo en un 69.3%, mientras que para el caso del WF-2 la reducción fue del 47,5%.
- Para el caso del WF-1, parque donde existía una mayor complejidad en la distribución de los aerogeneradores sobre el terreno (dispone de varias líneas de aerogeneradores según la dirección perpendicular a la predominante del viento), los modelos dinámicos obtenidos según la hipótesis 2, en la cual se le añadía una estación adicional a la capa de entrada de la ANN, mejoraron en todos los casos los resultados obtenidos según el modelo dinámico de la hipótesis 1. El grado de mejora para el MARE llegó a ser del 17,6%.

Para el caso particular del WF-2, donde ya inicialmente los resultados obtenidos para la precisión del modelo dinámico, según la hipótesis 1, eran muy buenos ($MARE < 0,1$), los resultados de los modelos generados según la hipótesis 2 fueron similares al primero.

- Cuando se utilizaron, como neuronas de la capa de entrada de la ANN, los datos meteorológicos de una estación ajena al parque eólico, en lugar de los propios de la estación de referencia del mismo (hipótesis 3), el grado de similitud entre el modelo dinámico así obtenido y el resultante según la hipótesis 1, era tanto mayor cuanto mejor fuera la correlación entre las velocidades de las estaciones de referencia y la ajena utilizada ("CC").
- Para un CC superior a 0,75, el grado de similitud entre los modelos dinámicos obtenidos según las hipótesis 1 y 3 fue superior a 0,9 (en una escala de 0 a 1, donde 1 representa el grado similitud óptima - figura 8.15 -)
- De los resultados obtenidos para los modelos desarrollados para la predicción a corto plazo (cap. 9 "caso A"), se observó que para un número de periodos, previos al de predicción, de hasta 24 horas, al aumentar el número de éstos siempre se mejoró la precisión de los modelos, independientemente del horizonte temporal de predicción. A partir de 24 horas previas, generalmente el modelo podía mejorar pero de forma insignificante. El grado de mejora obtenido era más importante cuando el horizonte temporal de predicción es igual o superior a 12 horas.
- Según el "caso A" estudiado en el cap. 9 y para los modelos concretos obtenidos para la predicción de los horizontes temporales $t+12$, $t+24$, $t+36$, siendo "t" el instante en el que se predice, se observó que el modelo podía mejorar el error (MARE) en un 13,2%, 11,2% y 8,3%, respectivamente y la correlación del modelo (R) en un 7,8%, 8,8% y 9,2%, respectivamente.
- Con el aumento del número de periodos, previos al de predicción, en las variables de la capa de entrada se conseguía además estabilizar más rápidamente el error de los diferentes periodos dentro de un horizonte temporal dado, Figuras 9.8 y 9.9
- Para el caso concreto del parque eólico analizado, la mejora en la predicción al aumentar el número de periodos previos en las variables de la capa de entrada, podría suponer un ahorro en la penalizaciones económicas por el desvío en el mercado eléctrico del 12,3%, equivalentes a 5.431,2€/año.
- La incorporación a la capa de entrada de la red neuronal de la información meteorológica de una estación adicional (Caso "B" de los estudiados en el cap. 9), ajena a la de referencia del parque eólico, mejoró la precisión de los modelos en el

76% de los 175 modelos generados en el "caso B". Aún así, al disponer de siete estaciones que se podían combinar como adicionales, para los 25 modelos desarrollados en el "caso A", siempre se encontró una que al incorporarla mejoraba los resultados obtenidos.

- La mejora que experimentaron los modelos al incorporar la segunda estación era tanto mayor cuanto mayor fuere el horizonte temporal de predicción, figura 9.11, pudiendo llegar el error (MARE) a mejorar en un 9,5% y la correlación del modelo (R) en un 5,3%.

10.4 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 resueltas 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 ANN para la predicción futura de la potencia del parque a corto plazo retroalimentando las salidas estimadas a la entrada de la red neuronal para volver a predecir.
- Aplicación de los modelos de ANN a predicciones a muy corto plazo, horizontes en torno al minuto, para estudios dinámicos.
- Generación de modelos de predicción a corto plazo utilizando otras técnicas de predicción y comparar los resultados. En este caso se podría analizar la idoneidad de la utilización de cada uno de los métodos según diferentes aspectos: rugosidad del terreno, complejidad en la distribución de las máquinas (influencia de las estelas), etc.
- 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 del modelo.

ANEXO I:

Artículos publicados derivados del trabajo de investigación realizado en la tesis

Artículo 1:

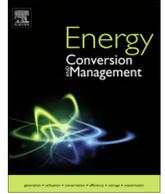
Título: "Sizing of a wind-hydro system using a reversible hydraulic facility with seawater. A case study in the Canary Islands"

Revista: Energy Conversion and Management, 106. 2015: pp. 1251-1263

Artículo 2:

Título: Influence of the reliability of short-term electrical power forecasting for a wind farm on the generation cost per MWh. A case study in the Canary Islands

Revista: Renewable Energy & Power Quality Journal, 13. 2015; nº páginas 6.



Sizing of a wind-hydro system using a reversible hydraulic facility with seawater. A case study in the Canary Islands



Ulises Portero^a, Sergio Velázquez^{b,*}, José A. Carta^c

^a School of Industrial and Civil 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, Universidad de Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^c 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

ARTICLE INFO

Article history:

Received 6 June 2015

Accepted 20 October 2015

Keywords:

Wind-hydro power plant
Pumped hydro energy storage system
Distributed generation

ABSTRACT

While the climatic conditions of the Canary Islands (Spain) are highly favourable for wind and solar energy exploitation, the low freshwater reserves are a problem when considering the implementation of hydro-based systems. For this reason, the pumped hydro storage (PHS) systems that have been proposed on the islands and which aim to exploit the available freshwater include an additional seawater desalination process.

Given this drawback, this paper proposes an original alternative: a reversible PHS facility which directly uses seawater with the system in this case located on the coast of Gran Canaria island. This facility would be used to manage and better integrate the energy generated by a wind farm into a weak insular electrical system. An analysis is also undertaken of the economic benefits the proposed wind-hydro system would entail for the island's electrical system.

As a result of the incorporation of the hydraulic unit, the contribution of the wind-hydro system in satisfying electricity demand is 29% higher than if a wind-only system is used. The electrical energy generation cost of the wind-hydro system amounts to 95.34 €/MWh, entailing an annual saving for the electrical system of 7.68 M€/year.

© 2015 Elsevier Ltd. All rights reserved.

1. Introduction

1.1. Background

The electricity grids of the Canary Archipelago (Spain) are comprised of independent electrical systems for each of the islands which are not interconnected (with the exception of the islands of Fuerteventura and Lanzarote which are connected by a 66 kV line). The transport networks are generally comprised of medium-voltage lines whose operating conditions, as determined by the low demand, are unsuitable for emergency situations or local failure. In short, the problem of independent island systems lies essentially in a lower quality of service and much higher costs [1].

The Canary Government, as part of its strategic planning in relation to electrical systems, includes prevision for the integration of electrical energy generation sources using non-manageable renewable technologies (mainly wind and photovoltaic). More specifically, a strategic objective was outlined in the Canary Islands Energy Plan (Spanish initials: PECAN) for renewable generation

sources to cover 30% of electricity demand by the year 2015 [2]. However, the contribution of renewable energies in terms of meeting electricity demand in the Canary Islands in 2014 was just 8% [3], a long way short of the PECAN objective.

The massive integration under secure safety conditions of non-manageable renewable energies in weak electrical systems requires energy storage installations that can guarantee a continuity of supply that renewable energies are unable to provide. Reversible hydroelectric systems are, in many situations, one way of solving this problem. Several studies have been published in the literature in relation to PHSSs as a solution for grid stability in the integration of non-manageable renewable energy sources [4–9]. Some studies, which have concentrated on specific island-based cases [6,7,9], have demonstrated the importance of such systems in maximizing the integration of non-manageable renewable energy sources in island-based electrical systems.

PHSSs help to adapt energy generation to demand by pumping water in periods of low energy demand and using that stored energy in periods of high demand, in this way maximizing the exploitation of primary renewable resources.

Bueno and Carta [10] undertook a specific PHSS study on the island of Gran Canaria (one of the islands of the Canary Archipelago) which contemplated the use of two of its most important

* Corresponding author. Tel.: +34 928 45 96 71; fax: +34 928 45 7319.

E-mail address: svelazquez@diea.ulpgc.es (S. Velázquez).

Nomenclature

CO ₂	carbon dioxide	EP _{WF}	energy performance of the wind farm (in MW h/MW)
COE	specific cost of the energy produced (in €/MW h). Eq. (7)	EP _{WHS}	overall energy performance of the wind-hydro plant (in MW h/MW). Eq. (13)
COE _{WF}	specific cost of the electrical energy relative to the wind farm (in €/MW h)	PECAN	Spanish initials for the Canary Islands Energy Plan
COE _{HS}	specific cost of the electrical energy relative to the hydraulic system (in €/MW h)	PHSS	Pumped Hydro Storage Systems
COE _{WHS}	specific cost of the electrical energy relative to the wind-hydro system as a whole (in €/MW h). Eq. (10)	REE	Spanish initials of Spain's electricity system operator
EP	energy performance (in MW h/MW). Eq. (9)	toe	tonne of oil equivalent

fresh water reservoirs. Padrón et al. [11] showed in a case study on the same island of Gran Canaria that the use of PHSSs improved wind energy penetration in the island's electrical system.

In the particular case of the Canary Islands and due to its climatic conditions, the availability of freshwater for direct hydro-power exploitation is very limited. The freshwater reserves are low, concentrated fundamentally in the centre of the islands and are mainly used to satisfy agricultural requirements. The year-round high temperatures result in much freshwater being lost to evaporation and, in general, freshwater reserves are being consumed faster than they are being replenished. Consequently, freshwater hydropower facilities need to have an additional seawater desalination process prepared to cover any deficit. The water product additionally needs to be transported from the plant, near the coast, to the more central areas where the freshwater reservoirs are found.

1.2. Aims

The original alternative that is proposed in the present paper is the use of a reversible hydraulic unit, located near the coast, to directly exploit the seawater. The installation of this type of system is conditioned by the characteristics of the coastal area of the site in question, in other words the presence of suitable height differences and sufficient space for the construction of the upper storage tanks and turbine/pump equipment.

The resulting hydraulic facility is intended to be used to improve the management and integration of the energy generated by a wind farm into the island's electrical system.

The specific aim is for the facility to be able to supply the electrical energy demands of La Aldea de San Nicolás (hereinafter referred to as La Aldea), a municipality located in the north-west of Gran Canaria island (Fig. 1).

An additional study has also been undertaken of the economic benefits of such a facility for the island's electrical system. These benefits are based on a reduction in production costs compared to the present conventional generation system.

The model proposed in this paper can be applied to any other insular and/or weak electrical system. The particular system studied in this paper is intended to serve as a reference for the Canary Island Government and Spain's electricity system operator for possible future implementation.

2. Methodology

The sizing undertaken in this paper will be based on the capacity, as far as is possible, of the wind farm to meet the energy demand of La Aldea. The wind farm will be connected to the island's electrical system. In the event of an energy surplus, with this being understood as a positive difference between the hourly wind-generated electrical power and the hourly electricity demand of La Aldea, the pumps of the hydraulic facilities will enter into

action raising the seawater to an upper level tank. The pumps will therefore be acting in this sense as a manageable load in the system. In the event that it is not possible to accumulate part or all the excess energy, this energy will still be fed into the island grid but will be consumed outside La Aldea municipality. This excess energy, which is not consumed by the system comprising the wind-hydro system and the corresponding electrical system of La Aldea, is called in this paper the equivalent energy surplus of the wind-hydro system. When the power generated by the wind farm is insufficient to meet energy demand, the energy deficit will be covered by the energy accumulated in the tank and/or, when necessary, by the island's electrical system (Fig. 2). The energy supplied in this way is described in this paper as the equivalent energy deficit. So, the operational hypothesis proposed in the present paper for the hydraulic plant is that it is always either pumping or turbinning, but that the two actions will not be carried out simultaneously.

Gran Canaria's high-voltage grid is comprised of 220 kV and 66 kV lines stretching a total distance of 419.2 km. Of these, 24% correspond to the 220 kV grid and the rest to the 66 kV grid [12]. La Aldea municipality is electrically connected to a 20 kV voltage as the high voltage grid of the island's system does not extend to this part of the island. In other words, La Aldea finds itself with an extra weakness in addition to the fragility of the island's electrical system.

A wind map of the Canary islands shows the high wind potential of the north-western region of the island where La Aldea is located [13]. The region has been included in the island's territorial planning for the future installation of wind farms.

The hourly electrical energy demand in the municipality of La Aldea and the capacity for wind energy exploitation at the potential site for the installation of the wind farm will be used as references for the sizing of the wind-hydro system. A model has been developed for the sizing implemented in the Matlab application (Fig. 3). Different cases were simulated based on this model. By using Matlab, we were able to implement our own programme routines and use its incorporated mathematical calculation tools.

In general terms, the model is comprised of a main programme which governs different subroutines. The most important of these subroutines are the five listed below:

- (a) Subroutine for the estimation of the electrical energy production of the wind farm.
- (b) Subroutine for the estimation of the energy demand of La Aldea.
- (c) Subroutine for the management of the energy balance (wind farm electricity production vs. La Aldea energy demand). Energy surpluses and deficits are managed on the basis of this energy balance.
- (d) Subroutine for the sizing optimization of the main components of the wind-hydro system (wind farm power, number and unit power of the reversible turbines, penstock, etc.).

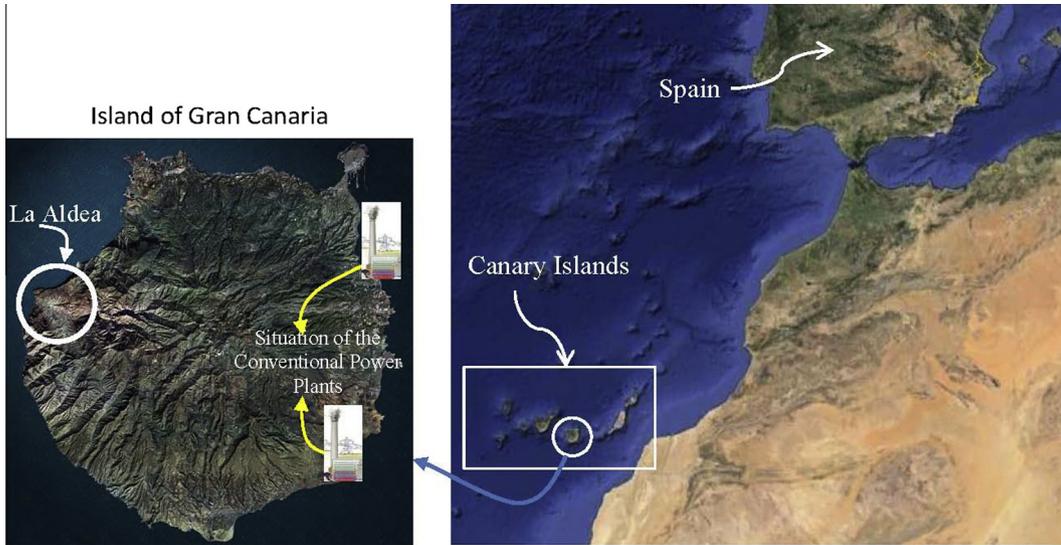


Fig. 1. Location of the area of study.

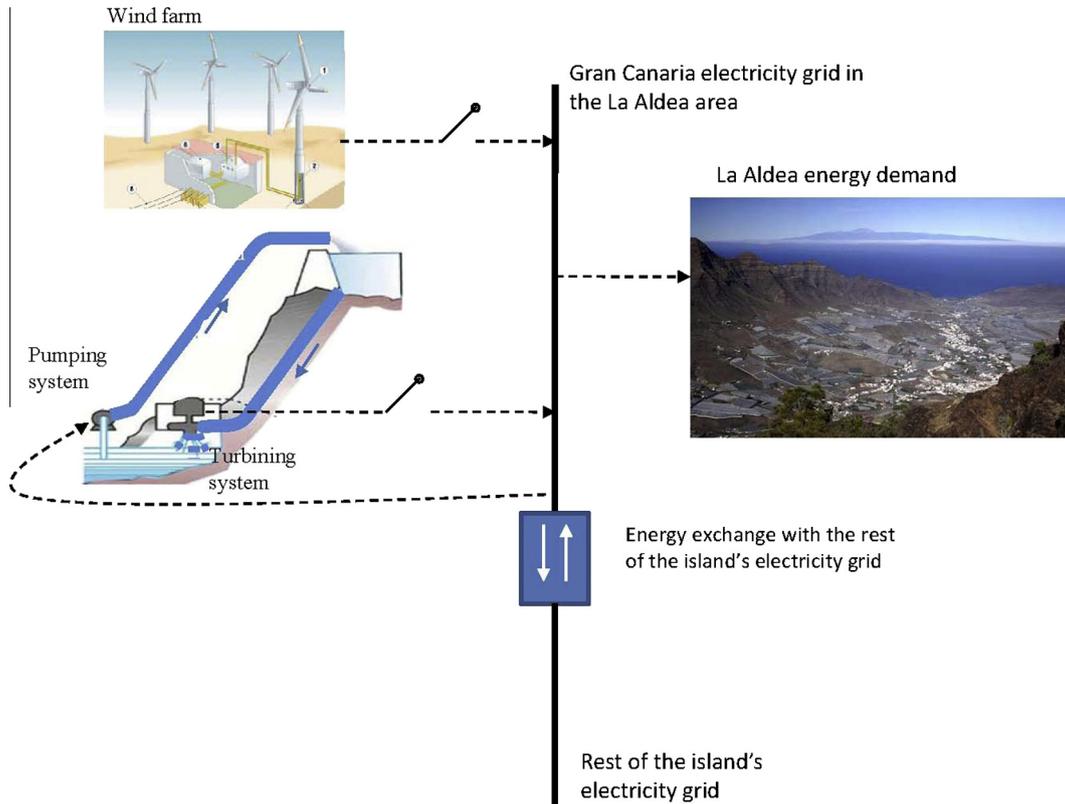


Fig. 2. Operational hypothesis of the wind-hydro installation.

(e) Subroutine for the graphical representation of the most relevant results.

2.1. Method used for sizing of the penstock of the hydraulic system

A single, 2000 m long penstock is planned in the system design connecting the turbine plant with the upper tank.

As the proposed system employs seawater, appropriate materials will be required to avoid corrosion and biological scaling. The pipeline will be made from FRP (Fibre Reinforced Plastic) and cov-

ered with protective layers against biological activity and attacks from both acid and base substances [14,15].

Eqs. (1)–(3) were considered for pipe diameter sizing:

$$P \times \eta_B = \rho \times g \times Q \times h_n \tag{1}$$

$$\frac{P}{\eta_T} = \rho \times g \times Q \times h_n \tag{2}$$

where

P: power (in W)

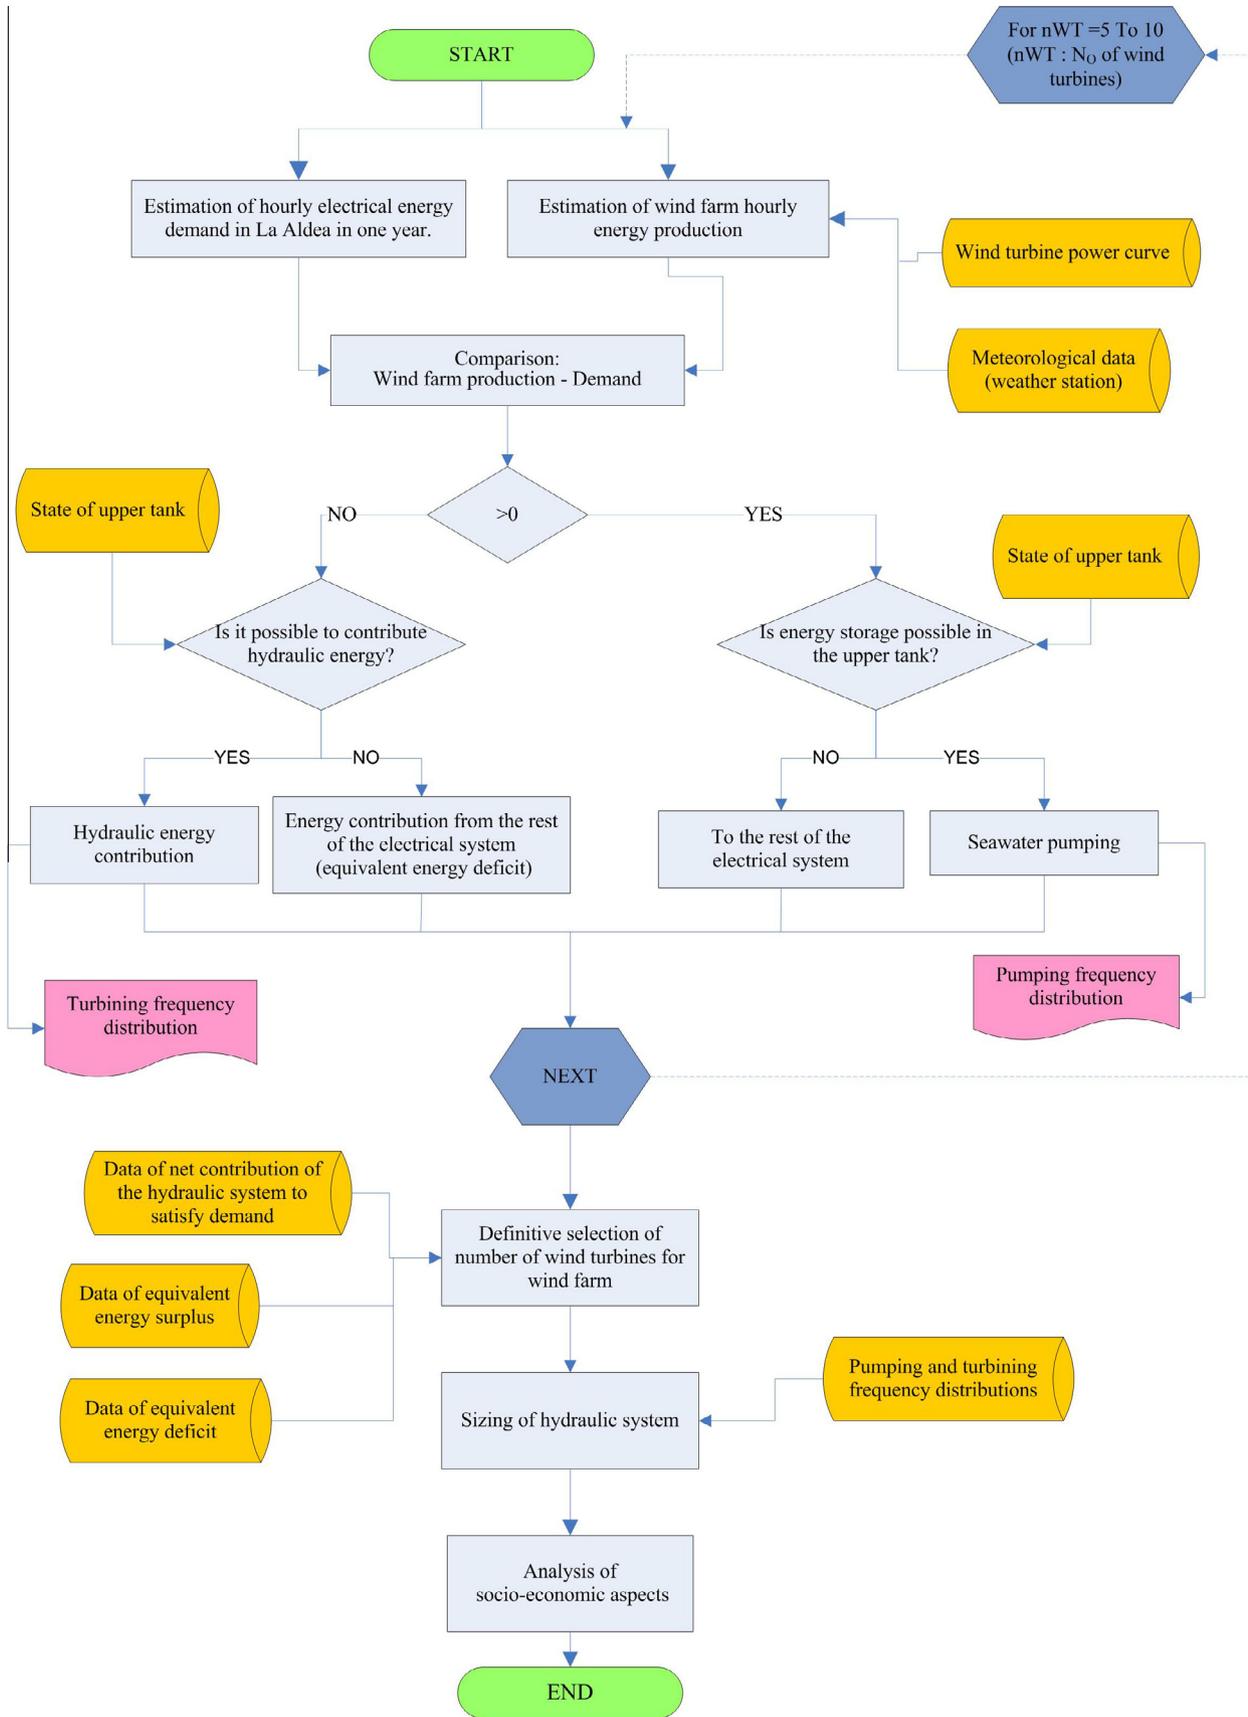


Fig. 3. Schematic representation of the model employed for the sizing of the wind-hydro system.

η_B : pumping efficiency of the hydraulic turbine
 η_T : turbinning efficiency of the hydraulic turbine
 ρ : seawater density (1025 kg/m³)
 Q : flow rate (in m³/s)
 h_n : net pumping/turbinning head (in m)

$$h_p = 10.3 \times n^2 \times \left(\frac{Q^2}{D^{5.33}} \right) \times L \quad (3)$$

where

h_p : Manning's formula for the calculation of energy loss in the pipeline [16] (in m)
 n : Manning's coefficient. This varies depending on the pipe material. For the particular case of FRP piping the mean coefficient is 0.009
 Q : flow rate (in m³/s)
 D : pipe diameter (in m)
 L : pipe length (in m)

Overpressure induced by the water hammer effect is calculated from Eq. (4)

$$\delta_p = \rho \cdot \frac{v \times c}{g} \quad (4)$$

where

δ_p : overpressure induced by the water hammer effect (in kg/m²)
 ρ : seawater density (1025 kg/m³)
 v : water speed before valve closure (in m/s)
 c : speed of the pressure wave, Eq. (5), (in m/s)

$$c = \sqrt{\frac{E}{\rho \cdot \left(1 + \frac{E}{E_B} \times \frac{D}{T} \right)}} \quad (5)$$

where

c : speed of the pressure wave (in m/s)
 E : modulus of elasticity of the seawater (2.27 × 10⁹ N/m²)
 E_B : modulus of elasticity of the pipe material (2.16 × 10⁸ N/m²)
 D : pipe diameter (in m)
 T : pipe thickness (in m)
 ρ : seawater density (1025 kg/m³)

2.2. Method employed to estimate the kWh generation cost of the wind-hydro system

The cost of electrical energy generation with the wind-hydro system was calculated from Eq. (6) [17–21]:

$$C_T = C_I + C_{O\&M} \quad (6)$$

where

C_T : total cost of the electrical energy generated (in Euros/MW)
 C_I : initial investment cost (in Euros/MW)
 $C_{O\&M}$: operating and maintenance cost (in Euros/MW)

For the purposes of this paper a simplified calculation model of the specific cost of energy (COE) was chosen, Eq. (7). This method, similar to the EPRI TAG method [18,20,21] estimates the cost as the ratio between the total costs and the annual electrical energy produced by the wind-hydro system.

$$COE = \frac{C_I \times FCR}{EP} + \frac{C_{O\&M}}{EP} \quad (7)$$

where

COE: specific cost of the electrical energy generated by the wind-hydro system (in Euros/MW h)
FCR: fixed charge rate per year, Eq. (8)

EP: energy performance of an electrical energy generation installation (in MW h/MW), Eq. (9)

$$FCR = \frac{r}{(1+r)^{Lt} - 1} + r \quad (8)$$

where

r : discount rate. A discount rate value of 0.04 (4%) was considered
 Lt : useful working life of the installation. Useful working lives of 20 and 40 years were considered for the wind and hydraulic installations, respectively. These correspond to the usual guaranteed working life of such types of installation

$$EP = \frac{\text{Electrical energy generated over a year}}{\text{Rated capacity of the electrical installation}} \quad (9)$$

Calculation of the COE, Eq. (7), of the wind-hydro system was carried out by adding together the COE of the wind installation and the COE of the hydraulic system. So, the overall COE is given by Eq. (10):

$$COE_{WHS} = COE_{WF} + COE_{HS} \quad (10)$$

where

COE_{WHS} : total COE of the wind-hydro system
 COE_{WF} : wind farm COE
 COE_{HS} : hydraulic plant COE

3. Materials

The energy demand forecast for La Aldea in a time frame up to 2020 was used as reference. Information available for the evolution of installed electrical power in the Canary Islands [12] and the evolution of the Canary population for the years 2000–2012 [22] were used as the initial data. A linear projection was made for the years 2013–2020 based on the evolution of these data. A value was obtained for installed electrical power per capita using the electrical power and population data. A similar projection was then made for La Aldea to the year 2020 based on the data available for evolution of the La Aldea population over the same period [22].

On the basis of the electrical power per capita data for the Canary Archipelago and the population data for La Aldea, an estimated value of 15.2 MW was calculated for installed electrical power in La Aldea in 2020 (Table 1). In this estimation it was assumed that the ratio of electrical power per capita in La Aldea was the same as that for the Canary Archipelago as a whole.

The behaviour of electrical energy demand for each of the independent island electrical systems was obtained from data supplied by the Spanish electricity system operator (Spanish initials, REE). An analysis of the daily evolution of demand for the specific case of the island of Gran Canaria [23] reveals two different behaviours, one representative of the days of the months from October to May (which we will call 'winter behaviour') and the other corresponding to the months from June to September (which we will call 'summer behaviour').

Table 1
Initial energy data.

Year	Canary population	La Aldea population	Installed power in the Canary islands (MW)	Installed power per inhabitant in the Canary Islands (kW/inh)	Estimated installed power in La Aldea (MW)
2020	2,508,981	9330	4088.2	1.74	15.2

Both representative behaviours are bimodal. However, the maximum values for a representative day of the ‘winter behaviour’ are different (the higher maximum value being that observed in the evening hours), whereas in the ‘summer behaviour’ the maximum values are very similar. In addition, the time during which demand remains constant between the two maximums is higher in the summer behaviour compared to the winter behaviour.

Gran Canaria island has a total installed power of 1178.3 MW [12].

Fig. 4 shows the behaviour of electrical energy demand in the municipality of La Aldea over a typical summer and winter day.

3.1. Estimation of wind-sourced electrical energy performance

Information provided by the Canary Island Technological Institute (Spanish initials: ITC), a Canary Government run company, was used to analyse the wind resources at the potential site for the location of the wind farm which will operate in combination with the hydraulic facilities. The values used were the mean hourly wind speeds and directions for the period 2000–2003, measured at a height of 10 m above ground level.

Fig. 5 shows the mean monthly wind speeds as well as the mean annual wind speed for the particular area. The highest mean wind speed values are found in the spring and summer months, exceeding in some cases 9.5 m/s. The mean annual wind speed is 7.1 m/s.

According to the results obtained in the calculation of wind direction frequencies, practically 80% of the wind directions of the year are concentrated in the sector contained between the NNE and SE directions.

The mean hourly wind speeds of a typical summer period day (June–September) and winter period (October–May) day were obtained from the hourly data. It can be seen in Fig. 6 that wind behaviour over the day is similar in the two periods considered, with the two curves practically parallel and separated by the different wind intensity of the two periods. Wind speed rises by an average of 3 m/s in the time period between 10:00 and 16:00, before gradually returning to values similar to those of the first hours of the day. This average increase entails a variation in wind power of 60% and 40% for the winter and summer periods, respectively.

The wind turbine model chosen for the proposed wind farm was the Enercon model E70/2300 kW [24]. The Enercon technology control system has been widely tested and has been used in previous research projects on weak electrical systems in the Canary Islands such as the SDAWES project [25].

Based on the mean hourly wind speed data for the reference zone and the power curves of the wind turbine [24], an estimation was made, using the quasi-dynamic method [26], of the hourly wind turbine power production for a typical year (Fig. 7).

It can be seen that the wind turbine works more hours at powers equal or close to its rated power during the April–August period.

3.2. Upper tank of the hydraulic facilities

The upper tank for storage of the pumped seawater will have a total volume of 9,206,278 m³. The available useful head of the hydraulic facility is 175 m.

The energy storage capacity of the tank is 4500 MW h (Eq. (11))

$$U_{TEC} = \rho \times V \times g \times h \times \frac{10^{-6}}{3600} \quad (11)$$

where

U_{TEC} : is the energy storage capacity of the upper tank (in MW h)

ρ : is seawater density (1025 kg/m³)

V : is the maximum volume of water that can be stored in the upper tank (in m³)

g : is gravitational acceleration (9.81 m/s²)

h : is the useful height of the upper tank (in m)

The interior of the tank will be covered with a 50 cm layer of 20 mm size gravel which will act as a drainage layer in the event of a leak or filtrations. Pipes with seawater sensor and pressure gauges will be connected to the drainage layer. In the event of a leak the detector will activate an alarm. The drainage layer will additionally be covered with a damping layer made from a non-woven geotextile material to avoid damage to the rubber membrane which will be the final layer.

An EPDM (ethylene propylene diene monomer) rubber membrane was chosen as the final lining of the upper tank. EPDM rubber is an elastomer with good abrasion and wear resistance.

3.3. Turbine of the hydraulic facilities

The system requires a reversible turbine capable of operating with seawater. The construction materials of the turbine are much more susceptible to damage from seawater compared to freshwater and, in consequence, a number of aspects need to be assessed and taken into consideration [15]. These include the need for easy assembly and removal of the runner for cleaning or replacement and simplification of the surface of the chute to avoid as much as possible corrosion in narrow areas or small fissures. In the head cover and discharge ring, the surfaces in contact with water are made from austenitic stainless steel with low carbon content. Surfaces with no water contact will be made from rolled steel for welded structures to keep costs low. The runner blades and hub will also be made from austenitic stainless steel with low carbon

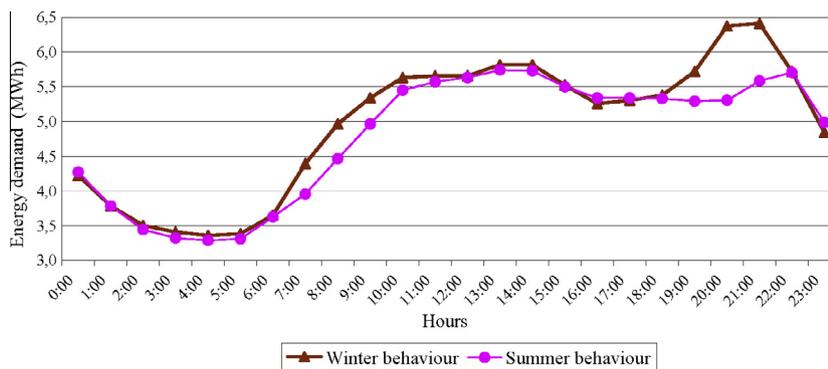


Fig. 4. Daily winter and summer behaviour of electrical energy demand in La Aldea municipality.

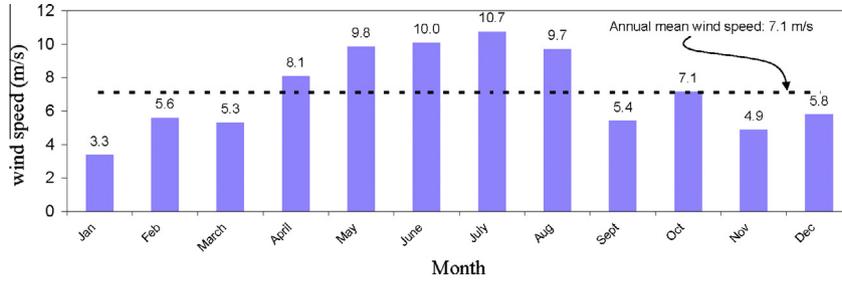


Fig. 5. Monthly mean wind speeds over a year (data collected 10 m above ground level).

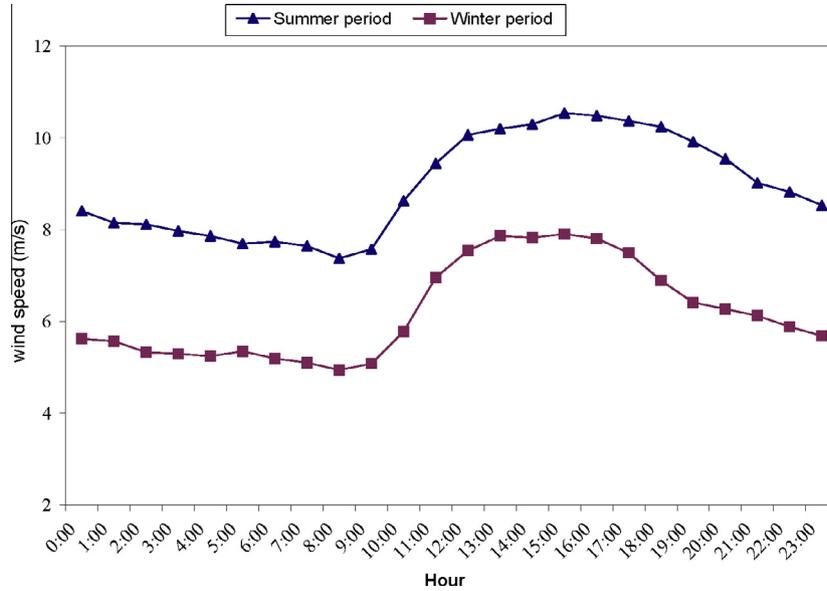


Fig. 6. Mean hourly wind speeds over a typical day (data collected 10 m above ground level).

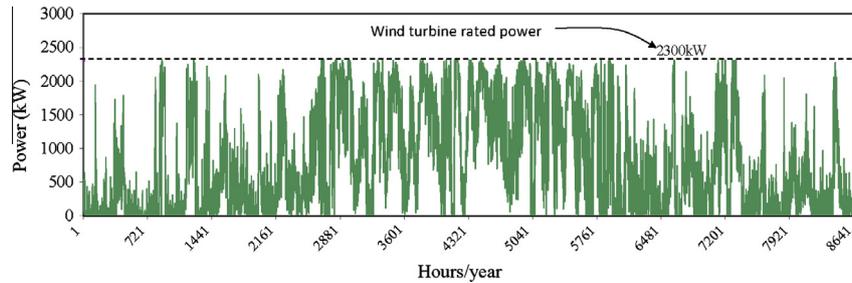


Fig. 7. Hourly wind turbine power production over a year for the Enercon E70/2300 kW wind turbine.

content and with nitrogen added to improve resistance to corrosion. The main shaft will be made from stainless steel and will have a slip ring to provide the current for cathodic protection against corrosion. Double distributor rod packing is required to prevent seawater entering into contact with the bearings.

Cathodic protection is employed to avoid corrosion as a result of damage to paintwork and the corrosion phenomena that appear in fissures. Given that higher flow rates accelerate the corrosion process, the cathodic protection will have an external power source in order to exploit an adjustable current for corrosion prevention.

Some marine microorganisms can stick to the surfaces of valves, turbines, pipes and other elements when the flow rate is below 5 m/s, resulting in a decrease in system efficiency. Water-repellent paint will therefore be used to prevent the adhesion of dirt and microorganisms in areas of low flow rate.

The Francis reaction turbine is the most commonly used type in modern reversible hydroelectric plants. Francis-type turbines have a high degree of adaptability to different useful heads (from 10 to 400 m) and flow rates (from 0.5 m³/s to 25 m³/s) [27] and have a wide operating range. Also popular are Kaplan-reaction turbines which can also work with an extensive range of flow rates (from 0 m³/s to 50 m³/s) but, unlike the Francis version, are only used for installations with useful heads below 60 m [27]. As the useful head available in our case is 175 m, it was decided to use the Francis type.

The efficiency of Francis turbines is over 80% when operating at between 40% and 110% of rated load, and around 75% at 20% of rated load [28]. The efficiency guaranteed by turbine manufacturers is based on the International Code for field acceptance tests of hydraulic turbines [29] or, when applicable, on the International Code for model acceptance tests [30].

The turbine distributor will be cylindrical and its main function will be to regulate the power of the turbine in function of its load. This is the most commonly used type of distributor in reaction turbines and can operate under variable load. Variable capacity can be obtained by modifying the turbine inlet flow via movable gates, called wicket gates [31].

The Francis turbine will be connected to an electrical machine. When the seawater flows from the upper tank to the sea, the turbine will operate in turbine mode, the electrical machine will act as a generator and the energy generated will be dumped into the island grid (Fig. 8). On the other hand, when seawater needs to be pumped to the upper tank, the electrical machine will act as a motor taking energy from the grid. In this case the Francis turbine will be acting as a pump (Fig. 8).

4. Results

4.1. Simulations

Based on the model developed in the present paper (Fig. 3), different simulations were performed to select the optimum number of wind turbines for the wind farm considering tank capacity, the annual energy demand curve for La Aldea and the wind turbine electrical energy production curve.

A total of 6 cases were simulated according to the number of wind farm turbines. Cases 1–6 considered the use of between 5 and 10 wind turbines, respectively.

By way of example, Figs. 9 and 10 show the results of the simulation of energy accumulation in the upper tank for cases 1 and 6.

The negative values observed in Figs. 9 and 10 indicate that the wind-hydro system is not satisfying energy demand. This energy deficit is then met by other generation sources coupled to the Gran Canaria island electrical system.

Two curves are shown in Fig. 10, one representing energy accumulation for the case of a 4500 MW h limitation and the other, which coincides in part with the first, representing accumulation variation with no storage capacity limit. Bearing in mind that energy accumulation is in fact limited to 4500 MW h, the area between the two curves will be the equivalent energy surplus of the wind-hydro system.

In the Case 1 simulation only one curve is represented as the energy accumulation never exceeds the energy capacity of the tank (Fig. 9).

The pumping and/or turbine needs for each hour (Fig. 11) are obtained as the difference between the power generated by the wind farm and the electrical power demand of La Aldea. If the result is positive, it is deduced that the difference will be power to be used for seawater pumping, and if the result is negative part of the accumulated water will need to be sent through the turbines to cover the energy deficit left by the wind farm.

Frequency distribution charts were made of the mean hourly pumping and turbine power requirements to enable a more precise interpretation of the results (Figs. 12 and 13).

4.2. Penstock of the hydraulic system

The least favourable operating condition of the hydraulic installation is used as the basis for calculation of the pipe diameter. In

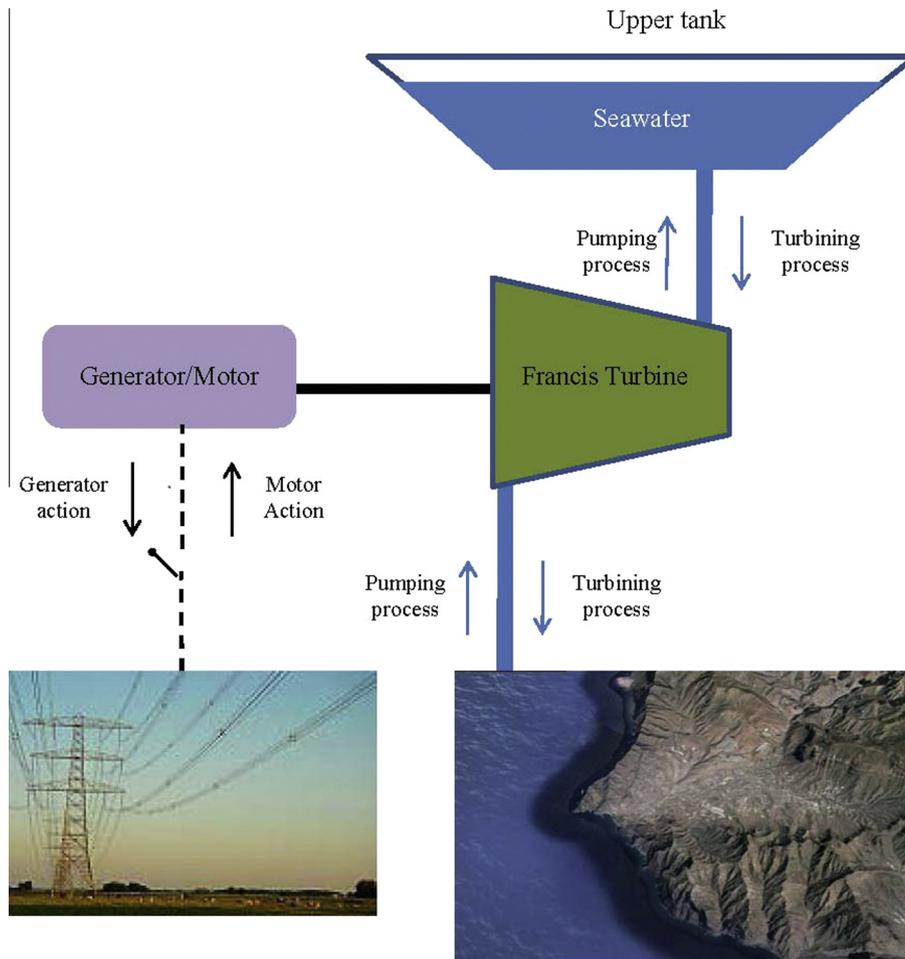


Fig. 8. Schematic outline of the operation of the reversible hydraulic system.

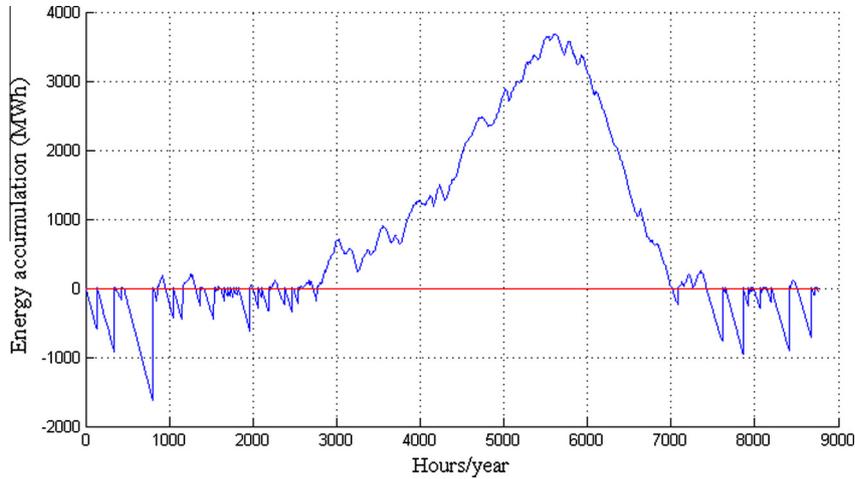


Fig. 9. Simulation of energy accumulation in the upper tank. Case 1: wind farm of 5 × 2300 kW wind turbines.

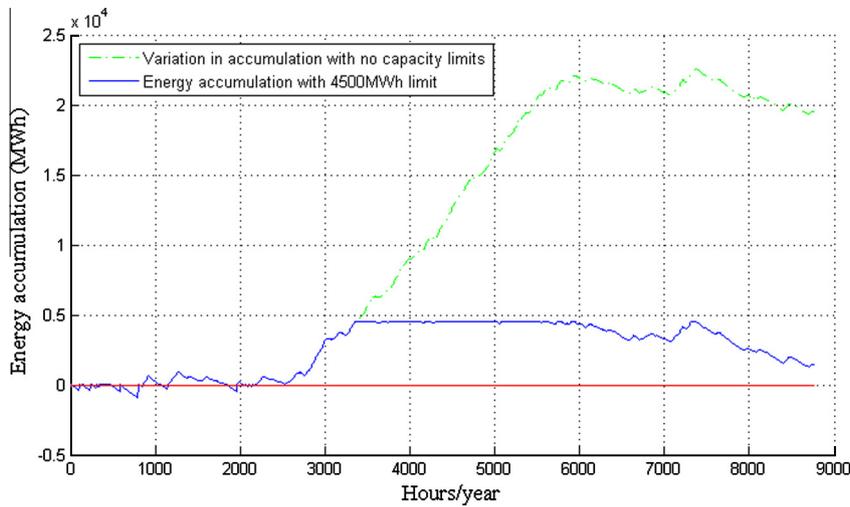


Fig. 10. Simulation of energy accumulation in the upper tank. Case 6: wind farm of 10 × 2300 kW wind turbines.

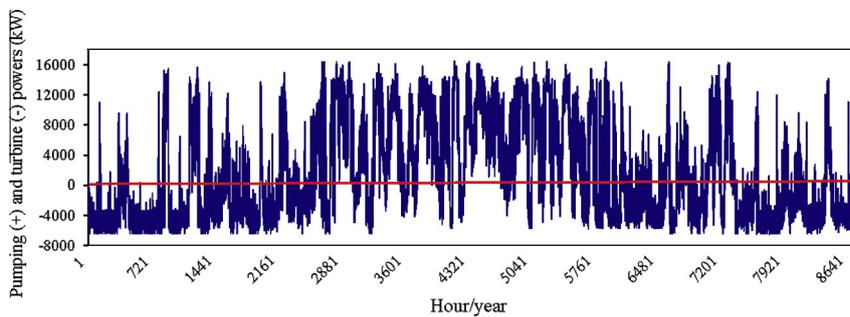


Fig. 11. Hourly variation of the pumping and turbine power requirements.

this particular study, this will be in the event of pumping power requirements of 16,000 kW, disregarding powers above this (Fig. 12). Based on the hypothesis that maximum energy loss in the pipeline does not exceed 5%, the maximum net pumping head, h_n , will be $175 \times 1.05 = 183.8$ m and, based on the same hypothesis and according to Eq. (1), $Q_{max} = 7.79$ m³/s.

Based on this flow value and applying Eq. (3), the diameter of the pipe should be greater than 1.58 m. A final diameter of 1.6 m and thickness of 12 mm was chosen for the pipe.

Real maximum losses in the pumping process will be 4.72% for the pipe diameter selected, Eq. (3).

In the same way, in the turbining process for a maximum power demand of 6000 kW (Fig. 13) and according to Eqs. (2) and (3), the maximum energy loss in the pipe is 1.14%.

Maximum flow rate is 3.66 m/s, Eq. (12).

$$Q = V \times A \tag{12}$$

where

Q: flow rate (in m³/s)

V: velocity of the fluid (in m/s)

A: cross-sectional area of the pipe (in m²)

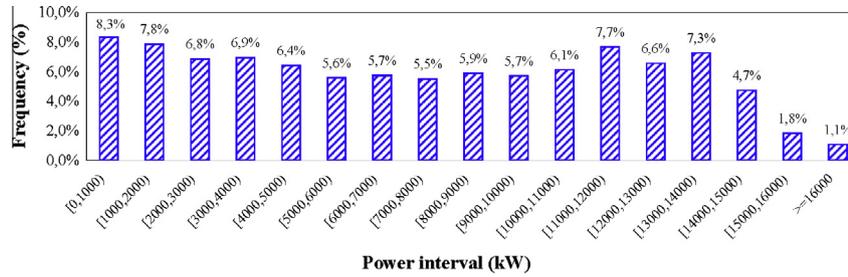


Fig. 12. Annual distribution of pumping power requirements.

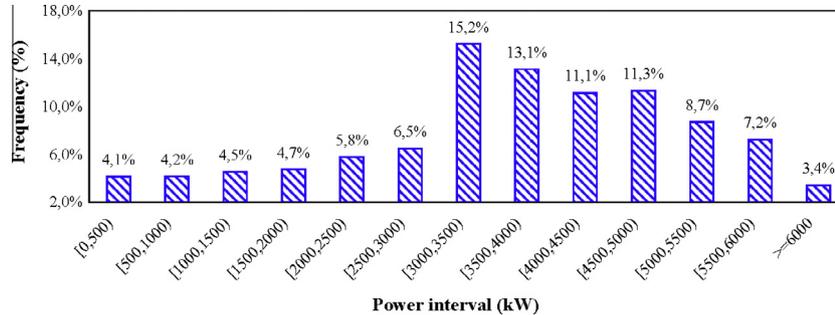


Fig. 13. Annual distribution of turbining power requirements.

Based on this velocity value, the overpressure induced by the water hammer effect amounts to 0.53 bar, Eqs. (4) and (5).

5. Discussion

5.1. Sizing of the wind farm

One characteristic is common to the results for all the simulated cases: an initial period between hours 0 and approximately 2600 (equivalent to the middle of the month of April) of zero net energy accumulation is followed by a second period, between hours 2601 and 5800 (the latter being equivalent to the start of September), in which there is net energy accumulation and a final third period, between hours 5801 and 8759, when energy accumulation decreases (see Cases 1 and 6 in Figs. 9 and 10, respectively).

The trends described in the previous paragraph are fundamentally based on the variation that takes place in the energy performance of the wind farm as a result of the fluctuation in wind potential in accordance with different seasons of the year (Figs. 5 and 7).

The results for the different simulated cases differ specifically in the magnitude of the energy deficits in the initial and final periods (as defined above), as well as in the amount of accumulated energy in the second period.

The parameters listed below were defined and calculated for the comparison and analysis of the different simulated cases:

- Relative contribution of the wind-hydro system to the demand of La Aldea.
- Relative contribution of the wind farm, without energy accumulation system, to the demand of La Aldea.
- Equivalent energy surplus of the wind-hydro system. This was calculated as a value relative to the energy demand of La Aldea.

Table 2 shows the results obtained for the above parameters. A notable increase can be observed in the energy contribution to demand of the wind-hydro system compared to the wind system

without energy accumulation. The energy contribution of the wind-hydro system to satisfy demand is 18% higher than that of the wind system alone for Case 1 (5 wind turbines) and this difference rises to 30.7% for Case 6 (10 wind turbines). This aspect is important in general, and in particular in weak electrical systems where the tendency is for distributed generation systems in which energy is consumed in the same place it is produced.

The following conditions were considered for the definitive selection of the size of the wind farm which will be associated with the hydraulic system: that the wind-hydro system has an energy demand contribution greater than 85%, that the equivalent energy surpluses relative to demand are not excessively high, and that the energy deficit is minimum for a given period of time. The overall aim is to minimise the impact of the wind-hydro system on the island's electrical system.

Only Cases 4–6 satisfy the threshold condition of 85% for the parameter concerning the energy demand contribution of the wind-hydro system. An important aspect that differentiates these three cases is that of energy deficit. In the period between hours 200 and 800, equivalent to the time from the second week of January to the first week of February, the amount of energy required from the island electrical system (i.e. not coming from the wind-hydro system) to satisfy demand was 1495 MW h, 937 MW h and

Table 2
Results obtained for the different simulated cases.

Id.	No. of wind turbines	% contribution of the wind-hydro system to satisfy demand	% contribution of the wind farm to satisfy demand (without energy accumulation)	Equivalent energy surpluses of the wind-hydro system (% over demand)
Case 1	5	69.5	51.5	0.0
Case 2	6	76.6	54.8	6.9
Case 3	7	81.3	57.4	16.3
Case 4	8	85.7	59.5	26.1
Case 5	9	90.2	61.2	36.0
Case 6	10	93.4	62.7	47.1

927 MW h for Cases 4, 5 and 6, respectively. Though the values for Cases 5 and 6 are similar, there is a marked difference of over 500 MW h between these two and Case 4. However, with respect to the parameter concerning equivalent energy surpluses of the wind-hydro system, Cases 5 and 6 are not similar, with Case 6 having an 11.1% higher energy surplus than Case 5 whereas its contribution to demand was only 3.2% higher.

In short, after analysing and studying all the cases an optimum wind farm configuration was determined comprising 9 Enercon E70/2300 kW wind turbines (9×2300 kW), giving a total power of 20.7 MW.

The starting hypothesis used in the simulations of the different cases was that the accumulation tank is initially empty. As can be seen from Fig. 10 (Case 6), the tank may have a surplus of accumulated energy at the end of the first year which needs to be taken into account for simulation of the following years. This only affects Cases 5 and 6 as in the other cases there is either no net energy accumulation at the end of the year or it is negligible with respect to demand.

Fig. 14 shows the simulation, for the selected case, of the energy accumulation process for the following year (steady-state regime) taking into consideration at the start of the year the surplus energy from the end of the previous one. As can be seen, this surplus is absorbed in the first hours of the year when the energy performance of the wind farm is lower and so the power generated by it is insufficient to cover demand. This means that the energy accumulation at the end of the year will be similar for each subsequent year.

5.2. Sizing of the hydraulic facilities

The actual pumping and turbine power requirements (Fig. 11) are variables that will depend on the wind farm generation regime and the electrical power demand of La Aldea, with maximum pumping power requirements of 16,000 kW and maximum turbine power requirements of 6000 kW. These results are key for the selection of the optimum rated power of the turbines for them to operate with high efficiencies.

In general terms it can be concluded from Fig. 11 that turbine power requirements are highest in the first and last months of the year, when wind potential is lower (Fig. 5) and the wind farm is unable to satisfy demand, whereas pumping power requirements are considerably higher in the hours corresponding to the summer period when there is an excess of wind power. The maximum pumping power requirements of 16,000 kW and maximum turbine power requirements of 6000 kW can also be seen in this figure.

It can be seen that the frequency distribution of pumping power requirements (Fig. 12) is practically constant up to approximately 15,000 kW, after which the pumping power requirements are practically negligible.

The distribution is not so constant in the case of turbinning power requirements (Fig. 13), with a 66.6% probability that these will be found between 3000 kW and 6000 kW.

If the aim is for the hydraulic turbine to operate for the longest time possible with efficiencies higher than 80%, then it will have to operate at between 40% and 110% of its rated load. This, together with the results obtained for actual pumping and turbinning power requirements (Figs. 12 and 13), are key factors for the selection of the optimum rated power of the turbines.

A system comprising 8 reversible 2000 kW turbines would be able to cover pumping power requirements working, in most cases, at between 40% and 110% of rated load. That is, the system of turbines can operate with efficiencies above 80% in the range between 800 kW (a single turbine operating at 40% of its rated load) and

17,600 kW (all eight turbines operating at 110% of rated load). In other words, the turbines would need to work beyond their normal operating range to cover a small percentage of the pumping needs (Fig. 12).

A similar analysis for turbinning power requirements showed that 2000 kW turbines under a normal operating regime would cover a large range of real turbinning power requirements.

In summary, a total of 8 and 3 turbines are required to meet pumping and turbinning requirements, respectively. Given that the proposed hydraulic plant will have just one pipeline (as the system will be either turbinning or pumping water, but not both at the same time), a total of 8 reversible 2000 kW hydraulic turbines will be required for the plant.

With this number and size of turbines and taking into consideration their efficiency curve [28] and the operating range frequency distribution (Figs. 12 and 13), the mean efficiencies obtained for the pumping and turbinning processes are 90% and 89.2%, respectively.

Fig. 15 shows the general layout of the resulting wind-hydro plant.

5.3. Economic benefits of the wind-hydro system

In order to estimate the kWh generation cost, Eq. (7), the energy performance (EP) of the wind-hydro system, Eq. (9), was first calculated.

Based on the results obtained for wind turbine electrical energy generation (Fig. 7), an estimation was made of the total energy generated in one year by the wind farm comprising 9 Enercon E70/2300 wind turbines. Using the value obtained and Eq. (9) the energy performance of the wind installation (EP_{WF}) was calculated.

$$EP_{WF} = \frac{71415.18}{20.7} = 3450 \frac{\text{MW h}}{\text{MW}}$$

For a final estimation of the energy performance of the wind-hydro system, consideration needs to be given to the fact that part of the energy generated by the wind farm to be fed into the electrical system is in fact subsequently stored in the hydraulic system because at that moment supply is exceeding demand. This energy will be sent to the turbines subsequently to satisfy demand when it is required.

The energy managed by the hydraulic system suffers certain additional losses as a result of the operation of the system itself. These losses correspond to the pumping and turbinning processes as well as those of the pipeline. Each of these losses has been previously calculated (Sections 4.2 and 5.2). Total losses in the hydraulic system amount to 26.7%, giving an energy efficiency (η_{HS}) of the hydraulic plant of 73.3%.

Of the total amount of electrical energy generated by the wind farm, 29% is managed by the hydraulic system (Case 5 in Table 3). The efficiency of the hydraulic system needs to be applied to this energy percentage in order to obtain the overall energy performance of the wind-hydro system, EP_{WHS} , Eq. (13). The final obtained value is 3182.9 MW h/MW.

$$EP_{WHS} = EP_{WF} \times 0.71 + EP_{WF} \times \eta_{HS} \times 0.29 \quad (13)$$

where

- EP_{WHS} : overall energy performance of the wind-hydro plant
- EP_{WF} : energy performance of the wind farm
- η_{HS} : energy efficiency of the hydraulic plant

5.3.1. Estimation of wind farm COE

The initial investment costs of the wind farm are estimated at 1.2 Me/MW [32,33] and operating and maintenance costs at 45,000 €/MW per year [32]. According to Eq. (7):

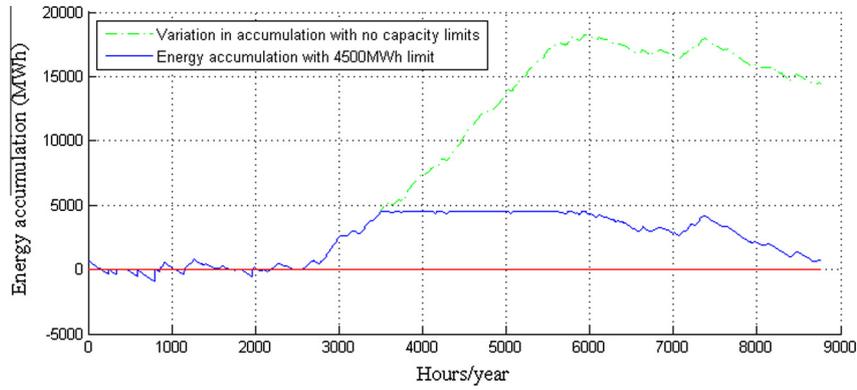


Fig. 14. Representation, for Case 5, of the variation, in steady-state regime, of energy accumulation for the wind-hydro system.



Fig. 15. General layout of the wind-hydro system.

Table 3
Breakdown of the total investment cost for the hydraulic plant.

Section	Description	Amount (M€)
I	Seawater accumulation tank	16.46
II	Civil works	1.79
III	Electromechanical equipment	12.37
IV	Electrical installation	0.59

$$COE_{WF} = \frac{1,200,000 \times 0.074}{3182.9} + \frac{45,000}{3189.2} = 42.04 \text{ €/MW h}$$

5.3.2. Estimation of the hydraulic plant COE

The estimated cost of the hydraulic plant amounts to a total of 31.21 Me (including taxes), equivalent to a specific investment of 1.95 Me/MW.

A breakdown of the total investment cost is shown in Table 3.

Among other aspects, Section 1 includes the drainage system and tank waterproofing to avoid filtrations; Section 2 includes the engine room, penstock and low pressure piping; Section 3 covers the eight 2 MW Francis-type reversible turbines with anti-corrosive alloy components, eight 2 MW generators connected to the turbines and eight 300 kW seawater suction pumps. Section 4

includes low- and medium-voltage electrical installations and the necessary transformers.

Annual operating and maintenance costs for the hydraulic plant were considered as equivalent to 3% of initial investment cost [34].

Based on the above data and in accordance with Eq. (7), the COE_{HS} is given by:

$$COE_{HS} = \frac{1,950,000 \times 0.057}{3182.9} + \frac{58,500}{3189.2} = 53.30 \text{ €/MW h}$$

So, in accordance with Eq. (10), a final COE_{WHS} value of 95.34 €/MW h is obtained.

The cost of electrical energy generation in island electrical systems is considerably higher than for mainland systems [35]. The average cost of electrical energy generation in 2014 in the Canary Islands was 211.9 €/MW h [36], far higher than the average price for the same year of 55.02 €/MW h in Spain's electricity market [37]. The regulatory system for electricity tariffs is applicable to the whole of Spain, including the Canary Islands, meaning that the difference between the average cost of electrical energy generation on the islands and the average price in the Spanish electricity market is equivalent to an economic deficit which is borne by the Spanish electricity system.

The specific generation cost as calculated for the wind-hydro system is far lower than the average cost of electrical energy generation in the Canary Islands, with the reduction in cost amounting to 116.56 €/MW h. After taking into consideration the annual electricity generation of the wind-hydro system, the equivalent saving for Spain's electricity system amounts to 7.68 M€/year ($20.7 \times 3182.9 \times 116.56$).

5.4. Environmental benefits of the wind-hydro system

The benefits to the environment as a result of the supply of electrical energy through renewable sources for the specific case considered in this paper was estimated in terms of savings in toe (tonnes of oil equivalent) and CO₂ emissions.

The total energy contribution of the wind-hydro system amounts to 65,886 MW h (20.7×3182.9). Considering the corresponding conversion factors [12], this energy is equivalent to 5666.2 toe and a reduction in CO₂ emissions of 51786.4 tonnes.

The saving in CO₂ emissions also entails an additional economic saving. Considering an expected price per tonne of CO₂ in 2020 of \$15 [38] and assuming €/€ parity, a maximum economic saving of 0.77 M€/year could be achieved.

6. Conclusions

The incorporation into the electricity grid system of Gran Canaria island of 20.7 MW of wind power in the municipality of La Aldea can be regulated through the installation of a 16 MW seawater-based PHSS.

The use of seawater in hydraulic systems can be a solution for areas where fresh water is not naturally in abundance. No desalination plant is required, and the need to construct and fit out a lower tank is obviated as the water is captured directly from the sea.

Through the incorporation of the hydraulic system as an element of regulation, the energy contribution of the wind farm rises by 29% (Table 2, Case 5) as part of a strategy of better use of distributed generation.

The total budgeted cost for the installation of the reversible hydraulic system amounts to 31.2 M€, equivalent to a specific investment of 1.95 M€/MW installed.

The lower cost of electrical energy through the wind-hydro system in comparison with the average cost for the Canary Islands would mean a saving of 7.68 M€/year.

Using the proposed system, an additional saving of 5666.2 toe is obtained as well as a reduction in CO₂ emissions of 51786.4 tonnes. The latter is equivalent to a further economic saving of 0.77 M€/year.

Acknowledgements

The authors would like to express their gratitude for the collaboration of the Canary Islands Technological Institute (Spanish initials: ITC) and to Emma Viera Ojeda, Industrial Engineer.

References

- [1] Calero R, Carta JA. Action plan for wind energy development in the Canary Islands. *Energy Policy* 2004;32:1185–97.
- [2] Canary Government Department of Employment, Industry and Commerce. Canary Islands energy plan revision 2006–2015 (Spanish Initials: PECAN 2006–2015); January, 2012. <http://www.gobiernodecanarias.org/energia/temas/planificacion/DOCUMENTO_REVISION_PECAN2006.pdf> [accessed 08.04.15] [in Spanish].
- [3] Spanish electrical system operator (REE). Yearly statistics of the Canary Islands' electricity system. <<http://www.ree.es/en/balance-diario/canarias/2014/12/31>> [accessed 24.05.15].
- [4] Ma T, Yang H, Lu L. Feasibility study and economic analysis of pumped hydro storage and battery storage for a renewable energy powered island. *Energy Convers Manage* 2014;79:387–97.
- [5] Kern JD, Patino-Echeverri D, Characklis GW. An integrated reservoir-power system model for evaluating the impacts of wind integration on hydropower resources. *Renew Energy* 2014;71:553–62.
- [6] Katsaprakakis Dimitris AI, Christakis Dimitris G, Stefanakis Ioannis, Spanos Petros, Stefanakis Nikos. Technical details regarding the design, the construction and the operation of seawater pumped storage systems. *Energy* 2013;55:619–30.
- [7] Katsaprakakis Dimitris AI, Chistakis Dimitris G. Seawater pumped storage systems and offshore wind parks in islands with low onshore wind potential, a fundamental case study. *Energy* 2014;66:470–86.
- [8] Rehman Shafiqur, Al-Hadhrani Luai M, Alam Md Mahbub. Pumped hydro energy storage system: a technological review. *Renew Sustain Energy Rev* 2015;44:586–98.
- [9] McLean E, Kearney D. An evaluation of seawater pumped hydro storage for regulating the export of renewable energy to the national grid. *Energy Proc* 2014;46:152–60.
- [10] Bueno C, Carta JA. Wind powered pumped hydro storage systems, a means of increasing the penetration of renewable energy in the Canary Islands. *Renew Sustain Energy Rev* 2006;10:312–40.
- [11] Padron S, Medina JF, Rodriguez A. Analysis of a pumped storage system to increase the penetration level of renewable energy in isolated power systems. Gran Canaria: a case study. *Energy* 2011;36:6753–62.
- [12] Canary Government. Canary Islands yearly energy report; 2013. <<http://www.gobiernodecanarias.org/ceic/energia/publicaciones/Anuario2012.pdf>> [accessed 08.04.15] [in Spanish].
- [13] Canary Government. Territorial information system. <<http://visor.grafcan.es/visorweb/>> (follow links "energia - mapa eólico") [accessed 24.05.15] [in Spanish].
- [14] Yōko Shibuya, Yōsuke Ishimura. *JSCCE Magaz* 2010;95(3):34–5 [ISSN 0021-468X].
- [15] Fujihara T, Himano H, Oshima K. Development of pump turbine for seawater pumped-storage power plant. *Hitachi Rev* 1998;47:199–202.
- [16] Manning R. On the flow of water in open channels and pipes. *Inst Civ Eng Ireland (ICE) Trans* 1891;20:161–207.
- [17] Hau E. *Wind turbines*. 2nd ed. New York: Springer; 2005.
- [18] Manwell JF, McGowan JG, Rogers AL. *Wind energy explained*. 2nd ed. Great Britain: John Wiley & Sons; 2009.
- [19] March F, Dlott EH, Korn DH, Madio FR, McArthur RC, Vachon WA. *Wind power for the electric-utility industry*. 1st ed. Massachusetts: Lexington Books; 1982.
- [20] Nelson V. *Wind energy*. 1st ed. FL: CRC Press; 2009.
- [21] Velázquez S, Carta JA, Matías JM. Comparison between ANNs and linear MCP algorithms in the long-term estimation of the cost per kWh produced by a wind turbine at a candidate site: a case study in the Canary Islands. *Appl Energy* 2011;88:3869–81.
- [22] ISTAC (Canary Islands Institute of Statistics). <http://www.gobiernodecanarias.org/istac/temas_estadisticos/demografia/poblacion/cifraspadronales/> [accessed 24.05.15] [in Spanish].
- [23] Spanish electrical system operator (REE). <<https://demanda.ree.es/visionaCan/VisionaGCanaria.html#>> (accessed 24.05.15) [in Spanish].
- [24] Enercon GmbH. ENERCON product overview, p. 14. <http://www.enercon.de/p/downloads/ENERCON_Produkt_en_web_032014.pdf> [accessed 24.05.15].
- [25] Carta JA, González J, Subiela V. The SDAWES project: an ambitious R&D prototype for wind-powered desalination. *Desalination* 2004;161:33–48.
- [26] 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.
- [27] Sangal S, Garg A, Kumar D. Review of optimal selection of turbines for hydroelectric projects. *Int J Emerg Technol Adv Eng* 2013;3:424–30.
- [28] Harano M, Tani Kiyohito, Nomoto Satoru. Practical application of high-performance Francis-turbine runner fitted with splitter blades. *Hitachi Rev* 2006;55:109–13.
- [29] IEC-41. Field acceptance tests to determine the hydraulic performance of hydraulic turbines, storage pumps and pump turbines; 1991.
- [30] IEC-193. International code for model acceptance tests of hydraulic turbines; 1965.
- [31] Beepers D, Branchini L, Orlandini V, De Pascale A, Perez-Blanco H. Pumped hydro storage plants with improved operational flexibility using constant speed Francis runners. *Appl Energy* 2015;137:629–37.
- [32] Institute for Energy Diversification and Saving of the Spanish Government (IDAE). Renewable energies plan 2011–2020; 2011 [in Spanish].
- [33] European Wind Energy Association (EWEA). Wind energy targets for 2020 and 2030; 2011.
- [34] Connolly D. The integration of fluctuation energy using energy storage. Limerick: University of Limerick; 2010.
- [35] Kapsali M, Anagnostopoulos JS, Kaldellis JK. Wind powered pumped-hydro storage systems for remote islands: a complete sensitivity analysis based on economic perspectives. *Appl Energy* 2012;99:430–44.
- [36] Spanish electrical system operator (REE). <<http://www.esios.ree.es/web-publica/>>; follow link "SEIE - Demand and Generation - generation price" [accessed 24.05.15].
- [37] Spanish electrical system operator (REE). <<http://www.esios.ree.es/web-publica/>>; follow link "MIBEL - energy price - final average price" [accessed 24.05.2015].
- [38] Luckow P, Stanton EA, Biewald B, Fields S, Jackson S, Fisher J, et al. CO₂ price report. Synapse Energy Economics Inc. [Spring 2014].



Influence of the reliability of short-term electrical power forecasting for a wind farm on the generation cost per MWh. A case study in the Canary Islands

Ulises Portero¹, Sergio Velázquez² and María Miranda¹

¹ School of Industrial and Civil Engineering, University of Las Palmas de Gran Canaria
Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain.
Tel.: +34 928 45 96 71, Fax: +34 928 45 73 19. E-mail address: uportero@yahoo.es, mmirandallobet@gmail.com

² 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).
Tel.: +34 928 45 96 71, Fax: +34 928 45 73 19. E-mail address: sergio.velazquezmedina@ulpgc.es

Abstract

The generation cost of a wind farm has generally been studied on the basis of two factors: the initial investment cost and the operating and maintenance cost.

The problems caused in an electrical system by deviations between the actual electrical power generated by a wind farm and the electrical power estimated by prediction models need to be corrected. These deviations result in an additional economic cost.

This paper evaluates the deviation cost per unit of energy generated by wind farms and analyses the contribution of this cost to the total production cost. The study undertaken in this paper has been made specific to the Canary Islands (Spain).

It can be deduced from the results of the study that the deviation cost can amount to between 1.5% and 15.5% of the cost of producing electrical energy generated by a wind farm depending, amongst other parameters, on the error made in the prediction. Wind farms that are otherwise deemed profitable may not be considered so if the deviation cost is taken into account.

Keywords: short-term wind power prediction, wind energy cost, electric energy market

1. Introduction

The strategic objectives of the European Union in general and on an individual basis of Spain and the Canary Islands [1-3] concerning the contribution that wind energy should be making to electricity demand by the year 2020, will require a considerable increase in installed wind power within that time frame.

The processes involved in the sale and purchase of energy in electricity markets require knowledge of the scheduling of generation bids for future periods of up to 48 hours [4-8]. Such knowledge is vital in the framework of a

liberalised electricity market, where the possession of accurate forecasts will allow favourable positioning of wind energy against other more conventional sources of electricity generation. This is even more true in weak electric systems, as may be considered the case of the Canary Archipelago (Spain) with its seven principal islands each of which has its own independent electricity system. For this reason, it is necessary to have very short-term (less than 48 hours) prediction models of the power output of wind farms.

A variety of errors in these models compromises their degree of reliability, resulting in many cases in the predicted values differing considerably from the actual measured values.

Various projects have been undertaken comparing different prediction tools presently in use with the aim of optimizing the results for short-term wind energy prediction. Two such projects which have been developed along these lines are ANEMOS [9-11] and Forecasting Exercise [12].

These projects attempt to take advantage of the potential of each of the prediction tools to create new improved tools. The different prediction tools were applied on an individual basis to each of the wind farms studied in the aforementioned projects.

For the purpose of comparing reliability in future electrical power forecasting, the authors of the ANEMOS and Forecasting Exercise projects used different metrics. For the study undertaken in this paper, the conclusions obtained from the Forecasting Exercise [12] for the metric which relates the forecast error with the actual measured power have been used. The Forecasting Exercise authors concluded that the mean value of the error, relative to actual production, for the case of individual wind farms was 55%, with 20% being the minimum error obtained by one of the forecast models.

To guarantee the supply and quality of the electricity, the system operator must be sure that the grids used to transport and distribute the energy are able to handle the amounts of this energy that are bought and sold in the market. The energy transactions of any particular day, D , are negotiated beforehand, generally on $D-1$. It is therefore extremely important that the negotiated energy bids are in fact available in the electricity system at the stipulated time. Any possible deviations that may occur in this sense will generate problems in that system. The system operator must act without delay to correct any power imbalances and guarantee the quality of the energy supply. These corrections to the electricity system entail an additional cost which is directly passed on to the electricity producers responsible for the imbalance [13-17]. In this paper, this cost has been called the deviation cost (C_d).

The cost structure of energy generation for a wind farm as considered to date in the scientific literature generally contemplates two factors: costs due to initial investment and operating and maintenance costs [18-21].

An evaluation is made in this paper of the mean deviation cost per unit of energy generated by a wind farm. An analysis will also be undertaken of the influence of the error committed in wind power prediction on the size of the deviation cost and on its contribution to the total

production cost. After incorporating the deviation cost, the new production cost will be compared with the average energy sale prices in the electricity market.

The calculations made in this paper are specific to the electricity system and market of the Canary Archipelago, which are in turn regulated by the system and market operators of Spain.

2. Initial Data

A. Meteorological data

The weather data used in this study correspond to the mean hourly wind speed data from six weather stations (WS-1 to WS-6) (Figure 1) for the period 1999-2010. The data were recorded at a height of 10 m above ground level. The stations are located in six of the seven islands of the Canary Archipelago; Lanzarote, Fuerteventura, Gran Canaria, Tenerife, La Palma and El Hierro.

The data were supplied by the official authorised State Meteorological Agency (Spanish initials: AEMET), part of the Spanish Government Ministry of Agriculture, Food and Environment, which also acts as the authorised aeronautical meteorological agency [22].

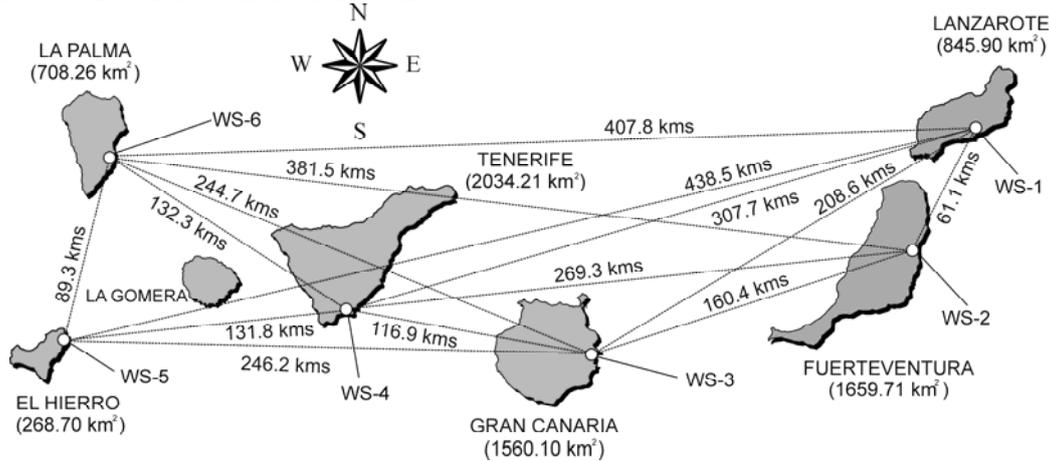


Fig. 1. Location of the weather stations used.

B. Wind turbine data

An Enercon E-70 wind turbine with rated power of 2300 kW was chosen for the wind-sourced electrical energy generation calculations.

Wind turbine manufacturers usually provide the power curves of their wind turbines in a discrete form with M nodes (P_{wt_j}, V_j ; where $j=1 \dots M$) [23].

3. Methodology

In the particular case of Spain's electricity systems, the deviation cost is determined for each hour of the year. Spain's transmission system operator (Spanish initials: REE), publishes the charge per unit of deviated energy (€/MWh) on its website [24].

The present analysis uses the mean values of the deviation charges, available for each hour of the year during the period from 2007 to 2011. The mean hourly deviation charges were calculated for each month of this five year period, Eq. (1).

$$\overline{Cd}_{h,m} = \frac{1}{N_y \times N_d} \sum_{d=1}^{N_d} \sum_{y=1}^{N_y} Cd_{h,m,d,y} \quad (1)$$

where:

$\overline{Cd}_{h,m}$; is the mean deviation charge for hour "h" of month "m" in the study period 2007-2011 (in Euros/MWh_{deviated})

$Cd_{h,m,d,y}$; is the deviation charge for hour "h" of day "d", relative to month "m" and year "y"

N_y ; is the number of years of the study period

N_d ; is the number of days of the month under consideration

Using the available mean hourly wind speeds from the different weather stations (Fig. 1) and the power curve of the chosen wind turbine, it is possible to estimate the mean hourly electrical power for each of the weather stations, $Pwt_{h,m,d,y}$.

where:

$Pwt_{h,m,d,y}$; is the electrical power of the wind turbine in hour “h” of day “d”, relative to month “m” and year “y” (in kW)

Gran Canaria and Tenerife are the most populated islands and account for 80% of the total installed power. It is expected that most of the Archipelago’s future wind farms will be installed on these two islands. For this reason, when estimating the hourly distribution per month of the electrical power of the wind turbine, this was weighted depending on the island where the reference weather station is located. This weighted power distribution was calculated to enable estimation of the weighted mean deviation costs.

As described for the deviation charges, using the hourly data of electrical power for the 12 years for which wind data were available (1999-2010), the mean electrical power for each hour of each month of the year, $\overline{Pwt_{h,m}}$, was estimated.

From the results obtained for the mean hourly deviation charges per month, $\overline{Cd_{h,m}}$; and the mean hourly electrical power per month, $\overline{Pwt_{h,m}}$, the values of the weighted mean monthly deviation cost are obtained, Eq. (2).

$$\overline{Cd_m} = \frac{1}{\sum_{h=1}^{24} \overline{Pwt_{h,m}}} \sum_{h=1}^{24} \overline{Cd_{h,m}} \times \overline{Pwt_{h,m}} \quad (2)$$

where:

$\overline{Cd_m}$; is the weighted mean deviation cost for month “m” (in Euros/MWh_{deviated})

Once the mean hourly electrical power per month has been obtained, it is possible to calculate the electrical energy for each month of the year, Eq. (3).

$$Ewt_m = \left(\frac{1}{24} \sum_{h=1}^{24} \overline{Pwt_{h,m}} \right) \times N_{h,m} \quad (3)$$

where:

Ewt_m ; is the electrical energy generated by the wind turbine in month “m” (in kWh)

$N_{h,m}$; is the number of hours in month “m”

Bearing in mind that the wind resource varies not only depending on the hour of the day but also over the

different months of the year, the weighted mean deviation cost in the year is calculated as shown in Eq. (4).

$$\overline{Cd} = \frac{1}{\sum_{m=1}^{12} \overline{E_m}} \sum_{m=1}^{12} \overline{Cd_m} \times \overline{E_m} \quad (4)$$

where:

\overline{Cd} ; is the mean deviation cost in a year (in Euros/MWh_{deviated})

To calculate the effect of this deviation cost on the total electrical power production cost of the wind farm, the value of the error which is committed in the forecast must be taken into account.

The metric used in this study relates the error with the actual measured production, Eqs. (5) and (6) [12].

$$MARE = \frac{1}{N} \sum_{i=1}^N EMAP_i \quad (5)$$

where:

MARE; is the Mean Absolute Relative Error

N; is the number of predicted time periods

EMAP_i; is the error relative to the actual measured power for the prediction period “i” of size “m”, Eq. (6).

$$EMAP = \frac{\sum_{h=1}^m |P_f(t+h) - P_m(t+h)|}{\sum_{h=1}^m P_m(t+h)} \times 100 \quad (6)$$

where:

$P_f(t+h)$; is the predicted power at instant “t” for hour “t+h”

$P_m(t+h)$; is the measured power at instant “t+h”

m; is the size of the forecast period. This can vary between 1 and 48 hours

With the results obtained from Eq. (4) and Eq. (5), it is possible to calculate the deviation cost per unit of generated energy, Eq. (7).

$$Cd_e = \overline{Cd} \times \frac{MARE}{100} \quad (7)$$

where:

Cd_e ; is the specific deviation cost or the mean deviation cost per unit of energy generated by the wind farm (in Euros/MWh_{generated})

As can be observed in Eq. (7), the specific deviation cost is a function of the error committed in the prediction of the electrical power generated by the wind farm. In this paper, an analysis is made of the effect of the deviation cost, as a function of the forecast error, on the total production costs of wind-sourced electrical energy. A comparison will also be made of the specific deviation cost, Cd_e , in relation to the sale price of the electrical energy.

Incorporation of the specific deviation cost, C_{d_e} , as a new factor in the production cost will affect the economic profitability of wind farms. The degree of this effect will depend on the error in the forecast and on the energy performance (EP) of the wind farm, Eq. (8). It is for this reason that the results have been made specific to this energy performance.

$$EP = \frac{\text{Electrical energy generated over a year by a wind farm}}{\text{Rated capacity of the wind farm}} \quad (8)$$

where:

EP; is the energy performance of a wind farm located in a particular area (in MWh/MW).

4. Analysis of results

If, in addition to the standard production cost structure used in the scientific literature [18-21], the cost factor analysed in this paper is also incorporated, then the total cost of the electrical energy produced by a wind farm can be calculated through Eq. (9)

$$C_T = C_I + C_{O\&M} + C_d \quad (9)$$

where:

C_T ; is the total cost of the electrical energy generated by a wind farm divided by the rated capacity of that farm in MW (in Euros/MW)

C_I ; is the initial investment cost divided by the rated capacity of the wind farm in MW (in Euros/MW)

$C_{O\&M}$; is the operating and maintenance cost divided by the rated capacity of the wind farm in MW (in Euros/MW)

C_d ; is the total cost due to deviations between predicted and measured electrical power divided by the rated capacity of the wind farm in MW (in Euros/MW_{deviated}).

For the purposes of this paper, a simplified calculation model of the specific cost of energy (COE) was chosen, Eq. (10). This method, similar to the EPRI TAG method [18-19] estimates the cost as the ratio between the total costs and the annual electrical energy produced by the wind farm.

The initial investment cost can be estimated at 1200000€/MW [26-27] and the operating and maintenance cost at 45000€/MW [26]. Taking into account these values, the expression for EP, Eq. (8), and the expression for specific deviation cost, Eq. (7), the specific cost of the electrical energy generated by a wind farm can be expressed by Eq. (10).

$$COE = \frac{C_I \times FCR}{EP} + \frac{C_{O\&M}}{EP} + C_{d_e} \quad (10)$$

where:

COE; is the specific cost of the electrical energy generated by a wind farm (in Euros/MWh)

FCR; is the fixed charge rate per year, Eq. (11).

$$FCR = \frac{r}{(1+r)^{lt} - 1} + r \quad (11)$$

where:

r ; is the discount rate. Taking as reference the cost of long-term Spanish debt a value has been assumed for the discount rate equal to 0.048 (4.8%)

lt ; is the useful life of the wind turbine. For this study, a useful life of 20 years has been assumed which corresponds to the warranty period given by the manufacturers

Table 1 shows the results obtained for mean monthly electrical power, $\overline{P_{wt_m}}$. It can be seen that the mean power varies depending on the season of the year.

To evaluate the energy contribution of each month to the total production over the year, the relative values were calculated using Eq. (12). Table 1 shows the results obtained. These are the results which represent the conditions of wind-sourced electrical energy exploitation in the Canary Archipelago.

$$Ewt_m(\%) = \frac{\overline{P_{wt_m}} \times N_{h,m}}{\sum_{m=1}^{12} \overline{P_{wt_m}} \times N_{h,m}} \times 100 \quad (12)$$

where:

$Ewt_m(\%)$; is the relative value of the electrical energy generated by the wind turbine in month "m" with respect to the total for the year.

$N_{h,m}$; is the number of hours in month "m"

$\overline{P_{wt_m}}$; is the mean electrical power of the wind turbine in month "m".

Table 1 Initial results

Month	$\overline{P_{wt_m}}$	$Ewt_m(\%)$	$\overline{C_{d_m}}$
Jan	286.5	4.34%	15.24
Feb	413.8	5.67%	13.70
Mar	504.9	7.65%	12.91
Apr	617.9	9.07%	10.94
May	646.8	9.81%	10.01
Jun	791.0	11.61%	9.51
Jul	1085.4	16.46%	9.80
Aug	865.8	13.13%	9.84
Sep	482.4	7.08%	12.11
Oct	340.3	5.16%	13.66
Nov	328.3	4.82%	13.72
Dec	344.0	5.22%	15.97

From the information published by the Spanish electricity system operator related to deviation charges [24] and by applying Eqs. (1) y (2), an estimation was made of the mean monthly deviation cost, $\overline{C_{d_m}}$. The results are shown in Table 1.

From the results obtained for the relative exploitation of the electrical energy, $Ewt_m(\%)$, and the mean monthly deviation cost, $\overline{C_{d_m}}$, calculation was made of the mean annual value of the deviation cost for each unit of deviated

energy. This cost for the period under consideration amounts to 11.47 €/MWh_{deviated}.

To calculate the mean electrical energy price we used the hourly data published on the Spanish Electricity Market Operator web site [25]. The hourly data for the year 2011 were used for the purpose of the particular analysis undertaken in this paper.

Following a procedure similar to that considered for calculation of the deviation cost, the result obtained for the specific mean sale price of the electrical energy (Pr_e) is 59.89€/MWh.

The specific production cost of electrical energy by a wind farm is a function of its energy performance, Eq. (8). From Eq. (8), it can be deduced that the higher the EP, the lower the cost due to initial investment and operating and maintenance. For this reason, the results have been made specific to the energy performance of the wind farm.

In Spain as a whole, the mean energy performance for the years 2007-2011 ranged between 2000 and 2200 MWh/MW. In the particular case of the Canary Islands, the corresponding values are between 2200 and 2600 MWh/MW [28]. For the year 2011, the mean EP of wind farms in the Canary Islands was 2425 MWh/MW [29].

For this reason, the results were analysed for an energy performance range equal to: $1800 \leq EP \leq 2800$.

The specific deviation cost, Cd_e , has been included in the production cost structure of the electrical energy generated by a wind farm (Eq. 10). This cost factor is a function of the error committed in short-term prediction, Eq. (7). Taking into consideration the mean results obtained for the error in studies carried out using different wind farms and different predictors [12], the results have been analysed in this paper on the basis of a range of mean forecast errors of 0% to 80%. In this way, the results that are obtained can be applicable to a wide variety of cases with wind farms of different characteristics and with different types of electrical power predictors.

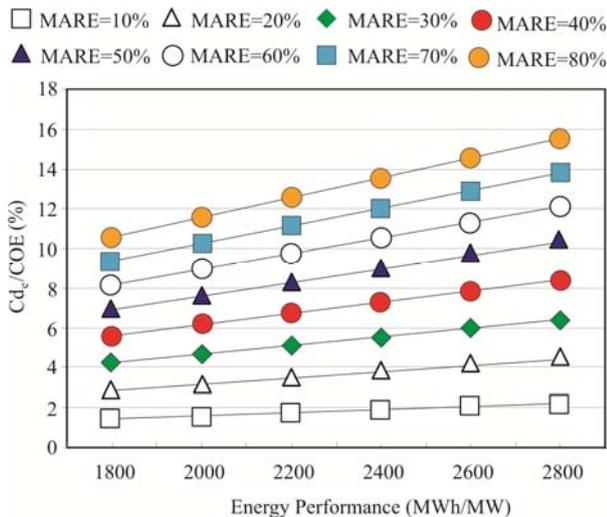


Fig. 2. Contribution of the deviation cost to the production cost of electrical energy by a wind farm.

Figure 2 shows the results of the contribution of the deviation cost to the total production cost of electrical energy generated by a wind farm as a function of the forecast error (MARE). It can be seen that the contribution

of the deviation cost rises with the forecast error. For the specific case of an EP of 2800 MWh/MW, the contribution of the deviation cost to the total cost can vary from 2.1% to 15.54% for MARE values of 10% to 80%, respectively.

Figure 3 compares the total production costs (COE) with the sale price of electrical energy (Pr_e).

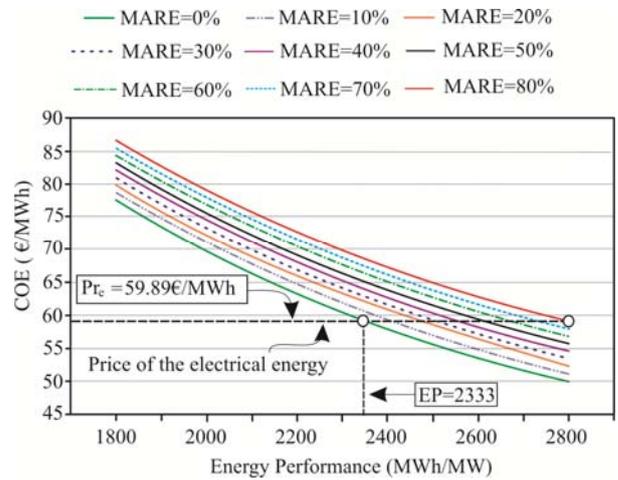


Fig. 3. Total production cost of the electrical energy generated by a wind farm (COE).

It can be observed in Figure 3 that, for the specific case in which there are no errors in the prediction, MARE=0%, in order for the total production cost to be lower than the sale price of the energy, Pr_e , the energy performance of a site has to be higher than 2333 MWh/MWh. However, if the prediction error is equal to 80%, in order for the total production cost to be lower than the sale price of the energy, Pr_e , the energy performance should be higher than 2800MWh/MW. So, the energy performance which is required of a site in order for the production cost not to be higher than the sale price of the energy has to rise as the forecast error increases. For the specific case of a wind farm with an EP equal to 2425 MWh/MW, equivalent to the mean value obtained for the Canary Islands in 2011 [29], the maximum possible mean relative error (MARE) in order for the COE to be lower than the Pr_e is approximately 10%, as can be deduced from Figure 3.

5. Conclusions

Deviations between the predicted and measured electrical energy production values for an established energy demand will give rise to alterations to the electrical system. Resolving these alterations will entail an additional economic cost which is proportionally passed on to the generation sources which have caused the deviation.

The authors of this paper propose that the specific deviation cost (Cd_e) should be considered as an additional factor in the cost structure of a wind farm's electrical energy production, Eq. (10). As shown in Figure 2, its contribution to the total cost depends on the forecast error. In an economic analysis of a wind farm project it is a necessary condition that the total production cost of the

electrical energy (COE) is lower than the specific sale price of the energy (Pr_e) or, in other words, than the income per unit of energy. The energy performance that is required of a wind farm located in a specific area so that the production cost will be lower than the sale price depends on the power forecast error.

For prediction errors of 0%, the energy performance has to be greater than 2333 MWh/MW. When the error rises to 80%, it has to be higher than 2800 MWh/MW.

In general, the economic cost associated with deviations between predicted and measured electrical energy production will lower the economic profitability of wind farms.

6. References

- [1] European Parliament and council, 2009. Directive 2009/28/EC of 23 April 2009 on the promotion of the use of energy from renewable sources. Official Journal of the European Union: pp L140/16 – L140/62
- [2] Government of the Canary Islands, 2005. Canary Islands Energy Plan 2006-2015 (PECAN 2006-2015). Regional Ministry of the Canary Government of Employment, Industry and Commerce, 2005. (in Spanish)
- [3] IDAE, 2011. Renewable Energies Plan 2011-2020. Institute for Energy Diversification and Saving (Spanish initials, IDAE). (in Spanish)
- [4] Spanish government, 1997. Royal Decree 1997/1997, dated December 26, on the organisation and regulation of the electrical energy production market. Official Spanish State Gazette, 310: pp 38047-38057 (in Spanish)
- [5] Spanish government, 2006. Royal Decree-Act 3/2006, dated February 24, on modification of the mechanism of matching sales and purchase bids presented simultaneously in the daily and intraday production markets by electricity sector participants belonging to the same company group. Official Spanish State Gazette, 50: pp 8015-8016 (in Spanish)
- [6] Spanish government, 2006. Correction of errors in Royal Decree-Act 3/2006, dated February 24, on modification of the mechanism of matching sales and purchase bids presented simultaneously in the daily and intraday production markets by electricity sector participants belonging to the same company group. Official Spanish State Gazette, 53: pp 8659-8659 (in Spanish)
- [7] Spanish government, 2006. Resolution dated May 24, 2006, of the Energy General Secretary by which approval is given to the operating rules for the daily and intraday electrical energy production market. Official Spanish State Gazette, 128: pp 20155-20192 (in Spanish)
- [8] European Parliament and council, 2003. Directive 2003/54/EC of 26 June 2003 concerning common rules for the internal market in electricity. Official Journal of the European Union: pp L176/37 – L176/55
- [9] ANEMOS. The State of the Art in Short-Term Prediction of Wind Power. http://www.anemos-plus.eu/index.php?option=com_content&view=article&id=91&Itemid=69 (accessed on 5 October 2014)
- [10] IDAE, 2007. ANEMOS study on wind forecasting in the European Union. Institute for Energy Diversification and Saving (Spanish initials, IDAE). (in Spanish)
- [11] Risø DTU., 2011. The State of the Art in Short-Term Prediction of Wind Power. A Literature Overview, 2nd Edition. Risø DTU, Wind Energy Division.
- [12] AEE, 2006. Ejercicio de predicción (Forecast Exercise). Wind Energy Association (Spanish initials: AEE). http://www.aeeolica.org/uploads/documents/aee_publica/informe_final_prediccion.pdf (accessed on 5 October 2014) (in Spanish)
- [13] Bergék A., Jacobsson S., 2010. Are tradable green certificates a cost-efficient policy driving technical change or a rent-generating machine?. Lessons from Sweden 2003–2008. Energy policy, 38: pp 1255-1271
- [14] Hasche B., Barth R., Swider D.J., 2007. Effects of improved wind forecasts on operational costs in the German electricity system
- [15] Jenner S., Groba F., Indvik J., 2013. Assessing the strength and effectiveness of renewable electricity feed-in tariffs in European Union countries. Energy Policy, 52: pp 385-401
- [16] Jónsson T., Pinson P., Madsen H., 2010. On the market impact of wind energy forecasts. Energy Economics, 32: pp 313–320
- [17] Ummels B.C., Gibescu M., Kling W.L., Paap G.C., 2006. Integration of Wind Power in the Liberalized Dutch Electricity Market. Wind Energy, 9: pp 579–590
- [18] Manwell J.F., McGowan J.G., Rogers A.L., 2009. Wind energy explained. 2nd ed. Great Britain: John Wiley & Sons.
- [19] Nelson V., 2009. Wind energy. 1st ed. FL: CRC Press
- [20] Velázquez S., Carta J.A., Matías J.M., 2011. Comparison between ANNs and linear MCP algorithms in the long-term estimation of the cost per kW h produced by a wind turbine at a candidate site: A case study in the Canary Islands. Applied Energy; 88: pp 3869–3881
- [21] Katzenstein W., Apt J., 2012. The cost of wind power variability. Energy Policy, 51: pp 233-24
- [22] AEMET, 2013. http://www.aemet.es/es/quienes_somos/que_es (accessed on 5 October 2014). (in Spanish)
- [23] Enercon, 2013. ENERCON product overview. <http://www.enercon.de/en-en/88.htm> (accessed on 5 October 2014).
- [24] REE, 2013. <http://www.esios.ree.es/web-publica>: Click on “MIBEL”, “ Measured Imbalances” and “RD 661/2007 Imbalances cost” (accessed on 5 October 2014)
- [25] OMEL, 2013. Market results. Spanish electricity market operator. www.omie.es/en/inicio (accessed on 29 July 2013)
- [26] IDAE, 2011. Renewable Energies Plan 2011-2020. Institute for Energy Diversification and Saving (Spanish initials, IDAE). (in Spanish)
- [27] EWEA, 2011. Wind energy targets for 2020 and 2030. European Wind Energy Association (EWEA).
- [28] Spanish transmission system operator, 2011. The Spanish Electricity System. www.ree.es/sistema_electrico/informeSEE.asp (accessed on 5 October 2014) (in Spanish)
- [29] Government of the Canary Islands, 2012. Canary Islands Energy Yearbook, 2011. http://www.gobiernodecanarias.org/industria/publicaciones/A_nuario2011.pdf: pp 107-119 (accessed on 27 July 2013). (in Spanish)

ANEXO II

Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

INDICE

A2.1 Introducción.....	2
A2.2 Descripción de las subrutinas utilizadas en MATLAB.....	2
A2.3 Funciones.....	2
A2.3.1 Función Curva de Potencia.....	2
A2.3.2 Función Ingenio.....	3
A2.3.3 Función Predicción horaria para una estación.....	7
A2.3.4 Función Predicción horaria para dos estaciones.....	10

A2.1 Introducción

La herramienta matemática MATLAB ha sido el entorno en el que se han implementado las diferentes FUNCIONES necesarias para el desarrollo del trabajo de investigación objeto de este documento. En este anexo se pretende dar una visión de las FUNCIONES utilizadas y una breve descripción de las mismas.

A2.2 FUNCIONES implementadas en MATLAB

Función 1: Mediante la misma se valora la eficiencia del modelo estático de curva de potencia de aerogenerador. Para ello se compara las estimaciones obtenidas con dicho modelo para la potencia eléctrica del parque eólico con los valores reales.

Función 2: Mediante ésta se genera el modelo dinámico de curva de potencia de parque eólico (DWFPC) aplicando las redes neuronales artificiales (ANN). Se comparan los resultados de eficiencia del modelo DWFPC con los del modelo estático.

Función 3: Mediante la misma se genera el modelo para la predicción a corto plazo de la potencia eléctrica de un parque eólico utilizando las redes neuronales artificiales.

Función 4: Se utiliza para generar los modelos de red neuronal para la predicción a corto plazo de la potencia eléctrica de un parque eólico en los casos donde en la capa de entrada de la ANN se utiliza la información de dos estaciones meteorológicas.

A2.3 FUNCIONES

A2.3.1 FUNCIÓN “Curva de Potencia”

```
function [Y] = curvapotencia(X,curva)
% CURVAPOTENCIA Summary of this function goes here
% Detailed explanation goes here
% Vector Y de salida de la potencia interpolada con la curva de potencia
pot
% y los datos de velocidad X

Y=[];
j=size(X,1);
%disp(j);
i=1;
%k=1;
pv=curva(:,1);
pp=curva(:,2);
%disp(pv);
%disp(pp);
%pause;
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
if j>i
    for i=1:j
        if X(i)<4 || X(i)>25
            Y(i)=0;
        else
            if X(i)>16 && X(i)<26
                Y(i)=700;
            else
                a=fix(X(i));
                %b=fix(a);
                b=X(i)-a;
                %for k=1:size(pv,1)-1
                %    if pv(k)==a
                %        c=pp(k+2)-pp(k+1);
                %    end
                c=pp(a+1)-pp(a);
                %end
                Y(i)=pp(a)+(c*b);
                %disp(c);
                %disp(b);
                %disp(Y(i));
                %pause;
            end
        end
    end
end
Y=Y';
end
```

A2.3.2 FUNCIÓN "Ingenio"

```
function [solucion] = ingenio5(X,T)
% "solucion" es una variable en la que está almacenada los datos net,
% tr(estructura), regresion,MSE, performance y output, para cada caso
llama
% a la función "netingenio"
% Las estaciones están representadas en pares

solucion={'Net', 'Estaciones', 'Regression', 'MSE', 'MARE', 'Perform', 'Vector
Entrada', 'Output', 'corr vel'};
i=2;
j=size(X,2);
%s=2;
%c=[];

if i<=j
    Z=X(:,i); %Matriz de 1x8760 Casos Velocidad de Gando
    c=i-1;
    [solucion] = netingenio(Z,T,solucion,i,c);
    i=i+1;

    for r=3:2:j
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
        Z=X(:,r); %Matriz de 1x8760 Sólo enfrentamos velocidades
        c=r;
        [solucion] = netingenio(Z,T,solucion,i,c);
        i=i+1;
    end

    for k=2:2:j
        Z=X(:,1:k); %Matriz de kx8760
        c=1:k;
        [solucion] = netingenio(Z,T,solucion,i,c);
        i=i+1;
        if k>2
            solucion{i-1,9}=corr(X(:,2),X(:,k)); %Correlación de la vel
gando                                     %con las demás Vel
entrantes
        end
        s=k+2;
        while s<j && k<j
            s=s+2;
            Z=[Z,X(:,s-1:s)];
            Z1=Z;
            c=[1:k,s-1:s];
            c1=c;
            [solucion] = netingenio(Z,T,solucion,i,c);
            i=i+1;

            for r=s+2:2:j
                Z=[Z1,X(:,r-1:r)];
                c=[c1,r-1:r];
                [solucion] = netingenio(Z,T,solucion,i,c);
                i=i+1;

                if r==j && s<j-2
                    Z=[Z1,X(:,s+1:r)];
                    c=[c1,s+1:r];
                    [solucion] = netingenio(Z,T,solucion,i,c);
                    i=i+1;
                end
            end
        end
        Z=X(:,1:k);
    end
end

end
end

function [solucion] = netingenio(X,T,solucion,i,c)
% UNTITLED3 Summary of this function goes here
% Detailed explanation goes here

% X es una matriz con todos los datos eólicos de dirección y velocidad de
% los parques Arinaga, FV, LZ, Gando y jinamar de 10x8760 -
% "datoseolicos"
% Y Es la matriz objetivo de la potencia de Ingenio 1x8760 - "target"
% Z es la matriz con los resultados red, correlación
"corr(target,output)",
% MSE "mse(net,target,output)",
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. NFTOOL falls back to this in low memory
% situations.

X=X';
T=T';

trainFcn = 'trainlm'; % Levenberg-Marquardt

% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivide
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
% net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
% 'plotregression', 'plotfit'};

% Train the Network
[net,tr] = train(net,X,T);
% Test the Network
Y = net(X);
error=T-Y;

%MARE=(sum(abs(error)./T)/size(error,2))*100; %Se halla el Error Absoluto
%Relativo Medio

m=0;
v=0;
pot=660*4;
for k=1:size(X,2) %Para hallar el MARE filtrando los valores pequeños
    if T(k)>=0.1*pot;
        m=m+abs(error(k)/T(k));
        v=v+1;
    end
end
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
MARE=m/v;  
%disp(Y);  
%pause;  
%disp(T);  
%MARE=MARE(Y,T);  
%e = gsubtract(t,Y);  
p = perform(net,T,Y);  
r = regression(T,Y);  
MSE=mse(net,X,T);  
%Y=Y';  
solucion{i,1}=net;  
solucion{i,2}=c;  
solucion{i,3}=r;  
solucion{i,4}=MSE;  
solucion{i,5}=MARE;  
solucion{i,6}=p;  
solucion{i,7}=X;  
solucion{i,8}=Y;  
end
```

A2.3.3 FUNCIÓN "Predicción horaria para 1 estación"

```
function [solucion] = predhora2(X,Z,var,var1)
% ARTICULO 2
% función que determina la predicción horaria cogiendo que solicita
tantas
% horas hacia delante a predecir como hacia atrás para el histórico
% X es la matriz de entrada con dirección, velocidad y potencia
"Art2datoseolicos"
% DVP es la matriz de salida con las predicciones y "cor" la correlación
entre
% la salida y el target, Pt salida vector para compararlo con el Target08
% Z es la matriz "costedesvio"
solucion={'NET','Dir-Vel-Pot','Pot.
Salida','net.Output','Regression','Media          Reg','MARE','Media
MARE','IoA(d)','Media          IoA(d)','NMAE','Media          NMAE','Desviación
SDE','','Coste Desvío','CD Medio'};

var=input('Ingrese las horas a tomar hacia atrás (t-nº): '); %Var=nº de
horas a tomar hacia atrás
var1=input('Ingrese las horas a predecir (t+nº): '); %Var=nº de horas a
predecir
DVP=[];
Pt=[];
Z1=[];
if var>var1
    va=var;
else
    va=var1;
end

for i=1:size(X,1)-2*va

    dir=X(i:i+var-1,1);
    vel=X(i:i+var-1,2);
    pot=X(i:i+var-1,3);
    DVP=[DVP;dir',vel',pot'];%hacemos la matriz X

    Pred=X(i+var:i+var+var1-1,3);%Sólo cogemos nº valores hacia delante
(var1=3)
    Pt=[Pt;Pred']; %hacemos la matriz salida a predecir, target

    Z2=Z(i+var:i+var+var1-1,1);%Sólo cogemos nº valores hacia delante
(var1=3)
    Z1=[Z1;Z2']; %hacemos la matriz salida de los costes de desvío

end

[solucion] = netingenio(DVP,Pt,solucion,var1,Z1); %Hallar la función
"ingenionet" y hallar la net, sacar la salida y hallar la corr Y,T

end

function [solucion] = netingenio(DVP,Pt,solucion,var1,Z1)
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
DVP=DVP'; %Antigua X, tratada para los datos de predicción horaria
Pt=Pt';

trainFcn = 'trainlm'; % Levenberg-Marquardt

% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivide
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
% net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
% 'plotregression','plotfit'};

% Train the Network
[net,tr] = train(net,DVP,Pt);
% Test the Network
Y = net(DVP);
error=Pt-Y;

m=0;
v=0;
MARE1=[];
NMAE1=[];
d2=[];
m1=0;
pot=660*4; %Potencia parque de Ingenio
%pot=850*9; %Potencia parque de Lanzarote
for j=1:size(Pt,1)
    error1=error(j,:);
    Pt1=Pt(j,:);
    Y1=Y(j,:);
    for k=1:size(Pt,2) %Para hallar el MARE filtrando los valores
    pequeños
        if Pt1(k)>=0.1*pot;
            m=m+abs(error1(k)/Pt1(k));
            v=v+1;
            m1=m1+abs(error1(k)/2640);
        end
        %disp(Pt(k));
    end
    MARE=m/v;
    MARE1=[MARE1,MARE];
end
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
NMAE=m1/v;
NMAE1=[NMAE1,NMAE];
mT=mean(Pt1); %media del target (valores observados)
d = 1-(sum((Y1-Pt1).^2)/sum((abs(Y1-mT)+abs(Pt1-mT)).^2)); %Hallamos
el IOA
d2=[d2,d];
end

%-----COSTE DESVIO-----
cd2=[];
cd1=abs(error);
cd1=cd1';
cd2=cd1.*Z1;%Se multiplica la matriz error con los CD
%for i=var1+1:size(Pt,2)
%   cd2=[cd2;cd1(i)*Z1(i)]; %Se multiplican los dos vectores uno a
uno
%end
cd=mean(cd2,1)/1000;%Se halla la media del vector resultante por
%columnas y se divide por 1000 para pasar de Mw a Kw.
cdt=mean(cd);%Media total (1 valor final de toda la matriz)

%-----

%p = perform(net,Pt,Y);
r = regression(Pt,Y);
r1=mean(r); %hallamos la media de la correlación
MARE2=mean(MARE1);
NMAE2=mean(NMAE1);
d3=mean(d2); %Hallamos la media del IOA
SDE=sqrt((sum((MARE1-MARE2).^2)/(var1-1))); %Desviación típica
%MSE=mse(net,X,Pt);

solucion{2,1}=net;
solucion{2,2}=DVP';
solucion{2,3}=Pt';
solucion{2,4}=Y';
solucion{2,5}=r; % Correlación por columnas
solucion{2,6}=r1; %Correlación total
solucion{2,7}=MARE1'; %Media por columnas
solucion{2,8}=MARE2; %Media total
solucion{2,9}=d2'; %IOA por columnas
solucion{2,10}=d3; %IOA total
solucion{2,11}=NMAE1'; %NMAE por columnas
solucion{2,12}=NMAE2; %NMAE total
solucion{2,13}=SDE; %SDE total
solucion{2,15}=cd; %Coste Desvío
solucion{2,16}=cdt; %Coste Desvío total (1 valor)

end
```

A2.3.4 FUNCIÓN “Predicción horaria para dos estaciones”

```
function [solucion] = predhora3(X1,T,Z,var,var1)
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
% ARTICULO 2 con "poenciaingenio9.mat"
% función que determina la predicción horaria cogiendo que solicita
tantas
% horas hacia delante a predecir como hacia atrás para el histórico PARA
% AÑADIR UNA ESTACIÓN MAS A LA DE REFERENCIA.
% X1 es la matriz de entrada con dirección y velocidad "datoseólicos" y T
el
% "target08", X es la matriz preparada para la simulación
% DVP es la matriz de salida con las predicciones y "coor" la correlación
entre
% la salida y el target, Pt salida vector para compararlo con el Target08
% Z es la matriz "costedesvio"

solucion={'NET', 'Dir-Vel-Pot', 'Pot.
Salida', 'net.Output', 'Regression', 'Media          Reg', 'MARE', 'Media
MARE', 'IoA(d)', 'Media          IoA(d)', 'NMAE', 'Media          NMAE', 'Desviación
SDE', 'Estaciones', 'Coste Desvío', 'CD Medio'};

var=input('Ingrese las horas a tomar hacia atrás (t-nº): '); %Var=nº de
horas a tomar hacia atrás
var1=input('Ingrese las horas a predecir (t+nº): '); %Var=nº de horas a
predecir

z=2;

if var>var1
    va=var;
else
    va=var1;
end
%disp(size(X1,2));
%pause;
for k=4:2:size(X1,2)
    DVP=[];
    Z1=[];
    Pt=[];
    c=[];
    X=[X1(:,1:2),X1(:,k-1:k)]; %cogemos la estación de referencia y Se le
añade la segunda estación
    c=[[1 2],k-1:k]; %Son fijas las dos columnas primeras y la que se le
añade
    disp(k);

    for i=1:size(X,1)-2*va
        %disp(i);

        dir=X(i:i+var-1,1); %Cogemos nº valores hacia atrás 1º estación
        vel=X(i:i+var-1,2);
        pot=T(i:i+var-1);

        dir1=X(i:i+var-1,3); %Cogemos nº valores hacia atrás de las demás
estaciones
        vell=X(i:i+var-1,4);
        DVP=[DVP;dir',vel',dir1',vell',pot'];%hacemos la matriz X

        Pred=T(i+var:i+var+var1-1);%Sólo cogemos Nº valores hacia delante
(var1) del target08/LZ
        Pt=[Pt;Pred']; %hacemos la matriz salida a predecir, target
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
    Z2=Z(i+var:i+var+var1-1,1);%Sólo cogemos n° valores hacia delante
    (var1=3)
    Z1=[Z1;Z2']; %hacemos la matriz salida de los costes de desvío

    end
    [solucion] = netingenio(DVP,Pt,solucion,var1,c,z,Z1); %Hallar la
función "ingenionet" y hallar la net, sacar la salida y hallar la corr
Y,T
    z=z+1;
end

end

function [solucion] = netingenio(DVP,Pt,solucion,var1,c,z,Z1)

DVP=DVP'; %Antigua X, tratada para los datos de predicción horaria
Pt=Pt';

trainFcn = 'trainlm'; % Levenberg-Marquardt

% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivide
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
% net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
% 'plotregression','plotfit'};

% Train the Network
[net,tr] = train(net,DVP,Pt);
% Test the Network
Y = net(DVP);
error=Pt-Y;
m1=0;
m=0;
v=0;
MARE1=[];
NMAE1=[];
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
d2=[];
pot=660*4; %Potencia parque de Ingenio
%pot=850*9; %Potencia parque de Lanzarote
for j=1:size(Pt,1)
    error1=error(j,:);
    Pt1=Pt(j,:);
    Y1=Y(j,:);
    for k=1:size(Pt,2) %Para hallar el MARE filtrando los valores
    pequeños
        if Pt1(k)>=0.1*pot;
            m=m+abs(error1(k)/Pt1(k));
            v=v+1;
            m1=m1+abs(error1(k)/2640);
        end
        %disp(Pt(k));
    end
    MARE=m/v;
    MARE1=[MARE1,MARE];
    NMAE=m1/v;
    NMAE1=[NMAE1,NMAE];
    mT=mean(Pt1); %media del target (valores observados)
    d = 1-(sum((Y1-Pt1).^2)/sum((abs(Y1-mT)+abs(Pt1-mT)).^2)); %Hallamos
el IOA
    d2=[d2,d];
end
%-----COSTE DESVIO-----
cd2=[];
cd1=abs(error);
cd1=cd1';
cd2=cd1.*Z1;%Se multiplica la matriz error con los CD
%for i=var1+1:size(Pt,2)
%    cd2=[cd2;cd1(i)*Z1(i)]; %Se multiplican los dos vectores uno a
uno
%end
cd=mean(cd2,1)/1000;%Se halla la media del vector resultante por
%columnas y se divide por 1000 para pasar de Mw a Kw.
cdt=mean(cd);%Media total (1 valor final de toda la matriz)

%-----

%p = perform(net,Pt,Y);
r = regression(Pt,Y);
r1=mean(r); %hallamos la media de la correlación
MARE2=mean(MARE1);
NMAE2=mean(NMAE1);
d3=mean(d2); %Hallamos la media del IOA
SDE=sqrt((sum((MARE1-MARE2).^2))/(var1-1)); %Desviación típica
%MSE=mse(net,X,Pt);

solucion{z,1}=net;
solucion{z,2}=DVP';
solucion{z,3}=Pt';
solucion{z,4}=Y';
solucion{z,5}=r; % Correlación por columnas
solucion{z,6}=r1; %Correlación total
solucion{z,7}=MARE1'; %Media por columnas
solucion{z,8}=MARE2; %Media total
solucion{z,9}=d2'; %IOA por columnas
solucion{z,10}=d3; %IOA total
solucion{z,11}=NMAE1'; %NMAE por columnas
solucion{z,12}=NMAE2; %NMAE total
```

Anexo II: Código fuente de las FUNCIONES más importantes implementadas en Matlab para la ejecución de la Tesis.

```
solucion{z,13}=SDE; %SDE total
solucion{z,14}=c; %Estaciones introducidas
solucion{z,15}=cd; %Coste Desvío
solucion{z,16}=cdt; %Coste Desvío total (1 valor)
end
```

