

Tesis Doctoral

Desarrollo de un sistema de pronóstico estocástico-dinámico de producción de energía eólica basado en el modelo WRF/CIMA

Waimann, Cristian

2016-08-16

Este documento forma parte de la colección de tesis doctorales y de maestría de la Biblioteca Central Dr. Luis Federico Leloir, disponible en digital.bl.fcen.uba.ar. Su utilización debe ser acompañada por la cita bibliográfica con reconocimiento de la fuente.

This document is part of the doctoral theses collection of the Central Library Dr. Luis Federico Leloir, available in digital.bl.fcen.uba.ar. It should be used accompanied by the corresponding citation acknowledging the source.

Cita tipo APA:

Waimann, Cristian. (2016-08-16). Desarrollo de un sistema de pronóstico estocástico-dinámico de producción de energía eólica basado en el modelo WRF/CIMA. Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires.

Cita tipo Chicago:

Waimann, Cristian. "Desarrollo de un sistema de pronóstico estocástico-dinámico de producción de energía eólica basado en el modelo WRF/CIMA". Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires. 2016-08-16.

EXACTAS UBA

Facultad de Ciencias Exactas y Naturales



UBA

Universidad de Buenos Aires



UNIVERSIDAD DE BUENOS AIRES

FACULTAD DE CIENCIAS EXACTAS Y NATURALES

DEPARTAMENTO DE CIENCIAS DE LA ATMÓSFERA Y LOS OCÉANOS

Desarrollo de un sistema de pronóstico estocástico-dinámico de producción de energía eólica basado en el modelo WRF/CIMA

Tesis presentada para optar al título de Doctor de la Universidad de
Buenos Aires en el área Ciencias de la Atmósfera y los Océanos

Cristian Waimann

Directores de tesis: Dra. Andrea C. Saulo

Dr. Alexis Hannart

Consejera de estudios: Dra. Andrea C. Saulo

Lugar de trabajo: Centro de Investigaciones del Mar y la Atmósfera -
UBA/CONICET

Buenos Aires, Junio 2016

Fecha de defensa: 16 de Agosto 2016

DESARROLLO DE UN SISTEMA DE PRONÓSTICO ESTOCÁSTICO-DINÁMICO DE PRODUCCIÓN DE ENERGÍA EÓLICA BASADO EN EL MODELO WRF/CIMA

Resumen

Los pronósticos de potencia eléctrica producida por aerogeneradores han cobrado relevancia en los últimos años, convirtiéndose en una herramienta importante para la optimización de los recursos energéticos principalmente en aquellos países donde la energía eólica posee una participación significativa dentro de la matriz energética.

Motivado por las políticas nacionales que fomentan el desarrollo de proyectos de energías renovables, se propone como objetivo general de la presente tesis, el desarrollo, evaluación, adaptación y documentación de diferentes sistemas de pronósticos de potencia eólica en la región noreste patagónica para plazos de pronóstico de horas a días.

Para plazos inferiores a 6 horas se propusieron métodos de pronóstico estadísticos basados en análisis de series temporales, mientras que para plazos superiores los métodos propuestos fueron contruidos combinando las últimas mediciones de potencia eléctrica con pronósticos numéricos de intensidad y dirección del viento. Para la construcción de los distintos métodos se contó con observaciones meteorológicas y de potencia eléctrica provenientes del Parque Eólico Rawson, y pronósticos numéricos realizados con el modelo WRF (Weather Research and Forecast).

Los resultados de los métodos estadísticos de pronóstico superan el desempeño de modelos de referencia de simple formulación como la persistencia, tanto para la intensidad del viento como para la potencia eléctrica. Los métodos contruidos para plazos superiores también superan al modelo de referencia propuesto aunque los errores medidos a través de diversos índices normalizados son mayores a los documentados en trabajos para otras regiones del mundo.

A partir de una colaboración científica establecida con la Universidad Tecnológica de Dinamarca y contando con una base de datos de más de 300 parques eólicos en la región continental de dicho país, otro de los objetivos generales de esta Tesis es la proposición y evaluación de métodos de pronóstico simplificados basados en la formulación de Wind Power Prediction Tool (WPPT), generalizando espacialmente los modelos propuestos a través de una interpolación derivada del método de Kriging. De esta forma es posible estimar con buen grado de precisión los parámetros que caracterizan los modelos de pronóstico para nuevos sitios, previamente a la construcción de nuevos parques eólicos dentro de la región de estudio, permitiendo pronosticar la potencia eléctrica para estos nuevos parques desde su primer momento de operación.

Palabras clave: Pronóstico de potencia eléctrica, viento, parques eólicos, modelos numéricos, Patagonia.

DEVELOPMENT OF A STOCHASTIC-DYNAMIC FORECASTING SYSTEM FOR WIND POWER BASED ON THE WRF/CIMA MODEL

Abstract

Wind power forecasts have gained relevance over the last years, becoming an important operational tool for the optimization of energy resources, especially in countries where wind energy has a significant participation in the energy market.

Driven by national policies that encourage the development of renewable energy projects, it is proposed as a general objective of the present Thesis the development, evaluation, adaptation and documentation of different wind power forecast methods in the northeastern Patagonian region, for forecasting horizons from hours up to days.

Statistical forecasting methods based on time series analysis were proposed for forecast horizons less than 6 hours, while for longer horizons different models were built combining the latest measurements of wind power with numerical forecasts of wind speed and direction. These models were constructed using meteorological and electrical power observations from the Rawson Wind Farm and numerical predictions made with the Weather Research and Forecast model (WRF).

Results derived from the statistical forecasting methods outperform simple reference models like persistence, both for wind speed and wind power. For longer forecast horizons, the hybrid methods also outperform the reference model although the errors measured by standardized indices are higher than those documented in studies for other regions of the world.

After a scientific collaboration established with the Technical University of Denmark and counting with a database of more than 300 wind farms in the continental region of the country, another general objective of this Thesis is the proposition and evaluation of simplified forecasting models based on the formulation of Wind Power prediction Tool (WPPT), and a spatial generalization of these models interpolating their coefficients through ordinary Kriging method. Results show the possibility to estimate with good degree of accuracy the parameters which characterize the forecast models for new sites prior to the construction of new wind farms within the region, allowing wind power prediction for the first time of operation of these wind parks.

Key words: Wind power forecast, wind, wind farms, numerical models, Patagonia.

Agradecimientos

A mis directores, Dra. A. Celeste Saulo y Dr. Alexis Hannart, por haberme guiado, formado y ayudado a lo largo del doctorado, otorgándome libertades en la exploración del tema y guiándome en los momentos más necesarios.

Al Dr. Pierre Pinson y la Universidad Tecnológica de Dinamarca, por haberme introducido en la temática de pronósticos de producción de potencia eólica, dedicándole valioso tiempo a mi formación. También una mención especial al Instituto Risø-DTU y a la Dra. Andrea Hahmann, por permitirme aprender de su experiencia.

Al Dr. Juan José Ruiz por su gran colaboración en distintas etapas de esta Tesis, y por las valiosas sugerencias y discusiones compartidas sobre diversos temas.

A la Compañía Administradora del Mercado Mayorista Eléctrico Argentino S.A (CAMMESA) por la información suministrada imprescindible para poder llevar adelante esta Tesis.

Al CIMA, DCAO y a la UMI por haberme dado un lugar de trabajo para realizar mi doctorado, y al CONICET por financiarlo.

A Presidencia de Nación, que a través del Ministerio de Ciencia, Tecnología e Innovación Productiva, financió mi estadía de 3 meses de duración en Dinamarca.

A mi familia, por el apoyo a lo largo de estos años.

A mis amigos de siempre y a los que tuve la suerte de encontrar en el camino!!.

A la CIPALM y Gondwana.

A mis abuelas...

Índice

Capítulo 1: Introducción	
1.1 Energía eólica: contexto global, regional y local	1
1.2 Pronósticos de potencia eólica: Generalidades	3
1.3 Objetivos generales	4
1.4 Estructura de la Tesis y objetivos específicos	5
1.5 Naturaleza del aporte original de la Tesis	6
 Capítulo 2: Descripción y análisis de la base de datos del Parque Eólico Rawson	 8
2.1 Parque Eólico Rawson: Ubicación geográfica y composición	8
2.2 Descripción de la base de datos	11
2.3 Variabilidad espacial en la escala del parque	13
2.4 Análisis de las series temporales: Variabilidad diurna y estacional del viento	19
2.5 Análisis de las series temporales: Variabilidad diurna y estacional de la potencia eléctrica	30
2.6 Relación entre la velocidad del viento y la potencia eléctrica: Proposición de distintas curvas de potencia	38
Referencias del Capítulo 2	44
 Capítulo 3: Evaluación del pronóstico del viento para distintas configuraciones del modelo WRF	 45
3.1 Introducción y motivación	45
3.2 Descripción de las simulaciones	47
3.2.1 Modelo WRF	47
3.2.2 Descripción general de las simulaciones: Selección de casos, condiciones iniciales y condiciones de borde	48
3.2.3 Selección de los dominios, proyección y resolución de las retículas	49
3.2.4 Niveles verticales	53
3.2.5 Selección de las parametrizaciones. Descripción de cada configuración	55
3.2.6 Pronósticos de GFS	61
3.2.7 Índices de error	61
3.3 Resultados	63
3.4 Discusión y conclusiones del capítulo	85
Referencias del Capítulo 3	87
 Capítulo 4: Formulación y validación de metodologías de pronóstico de potencia a corto y mediano plazo para el PER	 90
4.1 Introducción general del capítulo	92
4.2 Pronósticos a corto plazo – Método basado en modelos autorregresivos	94
4.2.1 Introducción y antecedentes	94
4.2.2 Modelos autorregresivos	95
4.2.3 Datos: Definición de los períodos de entrenamiento y evaluación	97
4.2.4 Aplicación de la metodología para el caso particular del PER: VIENTO	98

4.2.5 Aplicación de la metodología para el caso particular del PER: POTENCIA ELÉCTRICA	105
4.2.6 Métrica del error de pronóstico de intensidad del viento y potencia eléctrica	108
4.2.7 Comparación con respecto a un modelo simple de referencia	109
4.2.8 Resultados	109
4.2.9 Conclusiones de la sección	114
4.3 Pronósticos a corto plazo – Método basado en modelos lineales espaciotemporales	116
4.3.1 Introducción y antecedentes	116
4.3.2 Descripción general de la simulación	117
4.3.3 Configuración del modelo WRF	117
4.3.4 Modelos espacio-temporales para distintos regímenes de viento	118
4.3.5 Inferencia del modelo	119
4.3.5.1 Selección de regímenes de viento	119
4.3.5.2 Selección de predictores: Stepwise y estimación de los coeficientes de los modelos	121
4.3.6 Resultados	126
4.3.7 Conclusiones	142
4.4 Pronósticos de viento y potencia a 48 hs: Método combinado	144
4.4.1 Introducción y antecedentes	144
4.4.2 Datos del PER	146
4.4.3 Pronósticos de viento	146
4.4.4 Modelos de pronóstico de intensidad de viento	147
4.4.5 Transformación del viento a potencia: Curvas de potencia direccionales	150
4.4.6 Modelos de pronóstico de potencia eléctrica por regímenes de viento	152
4.4.7 Errores en los pronósticos de viento y potencia eléctrica para los modelos propuestos	153
4.4.8 Conclusiones	161
Referencias del Capítulo 4	163
 Capítulo 5: Formulación de modelos de pronóstico de potencia eléctrica para nuevos parques eólicos, utilizando la información histórica y los modelos combinados construidos para los parques eólicos existentes. Caso de Estudio: Dinamarca	166
5.1 Introducción del capítulo	166
5.2 Descripción del Método	169
5.2.1 Repaso de WPPT	168
5.2.2 Modelo simplificado basado en WPPT4	170
5.2.3 Generalización espacial de los modelos: Características principales de Kriging Ordinario	171
5.3 Implementación para el caso de estudio de Dinamarca	172
5.3.1 Datos	172
5.3.2 Diseño del experimento	174
5.3.3 Resultados	175
5.3.4 Discusión y conclusiones	181
Referencias del Capítulo 5	184
 Capítulo 6: Conclusiones generales	185

Capítulo 1

Introducción general

1.1 Energía eólica: contexto global, regional y local

Hacia fines de 2015, la capacidad total instalada de turbinas eólicas en el mundo alcanzaba valores record de 432.883 MW de potencia¹ continuando con un ritmo de crecimiento exponencial, siendo 2015 el año que presentó el mayor crecimiento anual desde el año 2000 en adelante. Justamente desde el año 2000 hasta el presente, la potencia instalada a nivel mundial aumentó aproximadamente 25 veces, mostrando un notorio impulso a la producción de energía eléctrica por medio de aerogeneradores. La Figura 1.1, tomada el último informe del Global Wind Energy Council (GWEC), presenta la evolución de la potencia mundial total instalada a través de los años.




Figura 1.1. Evolución anual de la potencia mundial total instalada. Fuente GWEC, 2016.

Este crecimiento exponencial observado en los últimos 15 años ha sido acompañado no sólo por avances tecnológicos propios del diseño de los aerogeneradores sino también por políticas económicas que han posibilitado su desarrollo. Asimismo, el comienzo hacia una nueva era de concientización sobre la reducción de emisión de Gases de Efecto Invernadero (GEI) con el fin de evitar el continuo aumento de la temperatura media global ha ido posicionando a la energía eólica, como a otras energías alternativas y renovables, como un reemplazo viable a la producción energética mediante la quema de combustibles fósiles.

¹ http://www.gwec.net/wp-content/uploads/vip/GWEC-Global-Wind-2015-Report_April-2016_22_04.pdf

Del total mundial de potencia instalada actualmente, 40.6% corresponde a Asia, 34.1% a Europa, 20.5% a Norte América, y el restante 4.8% se reparte en el resto del mundo.

Con respecto a Latinoamérica, de los 12.220 MW de potencia instalados, 71.3% corresponde a Brasil, 7.6% a Chile, 6.9% a Uruguay, y 2.3% a Argentina. El 11.9% restante se reparte en los restantes países de Sudamérica, Centroamérica e islas del Caribe.

Las perspectivas de crecimiento de la potencia mundial instalada son positivas para el período 2016-2020 para cada uno de los continentes y subcontinentes considerados, estimando un agregado total de 43.200 MW en Latinoamérica e islas del Caribe para finales del año 2020.

Con respecto al aprovechamiento local del recurso, el potencial eólico de la Argentina es uno de los mayores del mundo, no sólo pensando en la región patagónica, sino también en otras regiones del país, como el litoral marítimo bonaerense. Actualmente se encuentran instalados y en ejecución alrededor de 279 MW de potencia en distintos parques eólicos distribuidos en el territorio argentino, de un total de 31.815 MW de potencia total considerando todas las fuentes de producción de energía de nuestro país instalada² indicando que menos del 1% de la potencia proviene del recurso eólico. Asimismo la participación de la energía eólica es variable para cada región, representando 13.9% del total de la potencia instalada en la región patagónica, y 1.9% en el noroeste Argentino, siendo despreciable para el resto de las regiones.

De los 279 MW de potencia eólica instalada en Argentina, 64% se distribuye en los siguientes tres parques eólicos:

- Parque Eólico Rawson: Compuesto por 43 aerogeneradores Vestas V90 de 1.8 MW de potencia nominal, instalado al sur de la localidad de Rawson, en la región noreste patagónica, con una potencia total instalada de 77.4 MW. Actualmente es el parque eólico más grande de Argentina.
- Parque Eólico Loma Blanca: Este parque eólico se encuentra instalado entre las localidades de Puerto Madryn y Trelew, también en la región noreste patagónica. Está compuesto por 17 aerogeneradores Alstom ECO100 de 3 MW de potencia, totalizando 51 MW de potencia instalada.
- Parque Eólico Arauco: Compuesto por 26 aerogeneradores IMPSA IWP-83 de 2.0 MW de potencia, que totalizan 50.2 MW. Este parque eólico se encuentra instalado en el Valle de Arauco, Provincia de La Rioja.

El tercio restante se reparte entre pequeños parques eólicos y ejecución de obras de ampliación de parques eólicos existentes.

Sin embargo, y a pesar de este panorama actual en que la capacidad instalada dista mucho de su potencial, nuevas políticas nacionales han sido propuestas a fin de promover el desarrollo de energías renovables. El nuevo marco regulatorio argentino se basa en la Ley Nacional 27.191, relacionada al Régimen de Fomento Nacional para el Uso de Fuentes Renovables de Energía Destinada a la Producción de Energía Eléctrica. Esta reciente Ley sancionada en el mes

² Informe Anual 2015 - CAMMESA: www.cammesa.com.ar

de Septiembre del año 2015 y promulgada de hecho en Octubre del mismo año, plantea modificaciones a la Ley Nacional 26.190 sancionada anteriormente en el año 2006 y cuyos principales cambios se enumeran a continuación:

- Alcance: Se establece como objetivo del presente régimen lograr una contribución de las fuentes de energía renovables hasta alcanzar el ocho por ciento (8%) del consumo de energía eléctrica nacional, al 31 de diciembre de 2017.
- Se establece como objetivo de la Segunda Etapa del “Régimen de Fomento Nacional para el Uso de Fuentes Renovables de Energía Destinada a la Producción de Energía Eléctrica” instituido por la ley 26.190, con las modificaciones introducidas por la presente ley, lograr una contribución de las fuentes renovables de energía hasta alcanzar el veinte por ciento (20%) del consumo de energía eléctrica nacional, al 31 de diciembre de 2025.

Además, la Ley 27191 propone ciertos incentivos fiscales actualizados para el desarrollo de estos emprendimientos.

De manera consistente a la sanción de esta ley, el Gobierno Argentino anunció una licitación por más de 1 GW de proyectos de energías renovables, de los cuales alrededor del 50% de la potencia estará asociada a proyectos eólicos (Fuente: GWEC in Press, 20/05/2016). Todas estas acciones permiten vislumbrar un aumento considerable de la penetración de la energía eólica en la matriz energética local en los próximos años.

1.2 Pronósticos de potencia eólica: Generalidades

Hasta ahora las centrales eólicas no se tienen especialmente en consideración en el despacho del sistema eléctrico por ser muy pequeña su participación. No obstante, a medida que la potencia eólica instalada aumente dentro de una misma región, la energía suministrada por estos parques a las redes eléctricas deberá ser tenida en cuenta ya que localmente puede representar un porcentaje considerable del total de la energía dentro de una misma subred. Frente a esta problemática, el organismo encargado de la operación técnica del mercado eléctrico nacional requerirá herramientas técnicas confiables para realizar un eficiente manejo de los recursos eléctricos del país, pudiendo anticipar, planificar y aprovechar los momentos de alta producción de energía eólica. Esto se debe a que, a diferencia de otros mecanismos de producción de energía eléctrica capaces de controlar un mayor o menor influjo de energía hacia las redes, la energía eólica debe basar el manejo del recurso en la previsión del viento en capas bajas y su transformación en potencia.

La capacidad de pronosticar el estado de la atmósfera en un futuro cercano (desde horas a días) y su conversión a potencia, resulta de gran interés para los operadores del mercado eléctrico ya que permite optimizar las distintas opciones de generación disponibles para cubrir la demanda energética de la forma más económica y eficiente posible.

Existen 3 enfoques generales para abordar el problema de pronóstico de potencia eólica:

- i. Para plazos de pronóstico cortos, i.e hasta 6 horas, la velocidad del viento y la potencia se pueden pronosticar simplemente utilizando métodos de análisis de series temporales, sin recurrir a predicciones numéricas meteorológicas. Estos modelos están caracterizados por

utilizar los últimos valores observados de viento y otras variables para predecir la velocidad del viento futuro y la potencia eléctrica asociada, con muy buen desempeño.

ii. El segundo enfoque está referido al uso exclusivo de Modelos Numéricos de Pronóstico del Tiempo (MNPT). Típicamente los sistemas de pronóstico de potencia que utilizan MNPT tienen mejor desempeño que los que utilizan únicamente series temporales, para predicciones de más de 6 horas, por lo que resultan ser los más utilizados para tomar decisiones a nivel de sistema eléctrico y programar tareas de despacho diario y de mantenimiento del parque.

iii. El tercer enfoque hace uso del potencial de cada uno de los dos anteriores, i.e, generar un sistema combinado, donde las primeras horas de pronóstico sean mayormente descritas por una metodología estocástica, basada en la alta autocorrelación que tiene el viento y la potencia eólica, y el resto de las horas sean pronosticadas utilizando un MNPT configurados y corregidos para el sitio de interés. Si bien este tipo de estrategia tiene un alto desempeño debido a su formulación, también tiene los problemas inherentes a los 2 primeros enfoques; por ejemplo, el alto costo computacional que exigen los MNPT para obtener resultados con alta resolución horizontal y temporal. Estos sistemas combinados están siendo utilizados en muchos países operativamente para optimizar el manejo de sus recursos energéticos.

1.3 Objetivos generales

El primer objetivo general de la presente Tesis Doctoral es el desarrollo, adaptación y evaluación de métodos de pronóstico estadísticos y combinados, de viento y potencia eléctrica en alta resolución espacial y temporal, tal que se genere una herramienta de utilidad para la gestión de la energía eólica a nivel regional. Para ello se contó con datos de viento y potencia eléctrica provenientes del Parque Eólico Rawson (PER), instalado en la sección noreste de la región patagónica. Además, se propone analizar la naturaleza de los errores de pronóstico encontrados para el PER, a los fines de optimizar los modelos e identificar posibles líneas futuras de investigación que conduzcan a mejoras de valor para el manejo del recurso eólico.

Complementariamente, a partir de una colaboración científica entablada con la Universidad Tecnológica de Dinamarca (DTU), y contando con una base de datos de más de 300 parques eólicos en la región continental del respectivo país, junto con pronósticos de intensidad y dirección del viento provenientes de un MNPT; el segundo objetivo general de esta Tesis es la proposición y evaluación de modelos múltiples lineales de predicción horaria de potencia con características similares a las de Wind Power Prediction Tool (WPPT) analizando la variabilidad espacial y temporal de los errores encontrados, junto con la generalización espacial de los coeficientes de estos modelos a través de Kriging Ordinario (KO). El fin último de esta tarea es probar hasta qué punto la interpolación espacial de los parámetros que permiten generar los modelos de pronóstico puede ser empleada para estimar por interpolación parámetros en una nueva ubicación geográfica, donde no se cuenta con datos previos. Así antes de instalar un nuevo parque eólico se contaría, no solo con la estimación de la potencia sino con un modelo de pronóstico simplificado desde el minuto cero de funcionamiento de un parque. De este modo se puede incluir efectivamente en el despacho de energía hasta que un conjunto suficiente de mediciones de potencia pueda ser realizado y así poder calcular los parámetros específicos de este parque.

1.4 Estructura de la Tesis y objetivos específicos

El primer objetivo general de la Tesis, asociado al caso de estudio del Parque Eólico Rawson, se divide en los siguientes tres capítulos con distintos objetivos específicos.

El Capítulo 2 presenta una descripción de la base de datos del PER, en conjunto con un análisis de las distintas variables que la componen, presentando un estudio de la variabilidad diurna y estacional, del viento y la potencia eléctrica.

El Capítulo 3 está asociado al modelado numérico de la atmósfera. En este capítulo se proponen y evalúan distintas configuraciones del modelo Weather Research and Forecast (WRF) en alta resolución espacial, modificándose aquellas parametrizaciones que puedan modificar sustancialmente la representación del flujo de aire en capas bajas. En particular se evalúa el desempeño del modelo bajo distintas parametrizaciones de capa superficial y capa límite, para las estaciones estival e invernal, analizando los errores de estas simulaciones para distintos regímenes de estabilidad y plazos de pronóstico, analizando su ciclo diurno e identificando sus componentes sistemáticas y no sistemáticas.

El Capítulo 4 es el núcleo principal de la presente Tesis, y está subdividido en tres secciones con metodologías y objetivos específicos bien diferenciados. En la primera subsección se proponen y validan métodos de pronósticos horarios de potencia eléctrica a corto plazo (hasta 12 hs) para el Parque Eólico Rawson. La formulación de los pronósticos para plazos menores a 12 horas depende principalmente de la implementación de metodologías de análisis de series temporales debido a la naturaleza persistente del viento, y en particular se propondrán y evaluarán los desempeños de distintos modelos autoregresivos, respecto a un modelo simplificado de referencia.

Complementariamente y debido a la escasez de estaciones de medición de viento en la región noreste patagónica, se decidió realizar una simulación idealizada del viento en capas bajas con el modelo WRF para esta región. En este contexto cada punto de retícula del dominio simulado fue considerado como una estación meteorológica, considerando la serie temporal del punto de retícula más cercano al PER como su serie “observada”. El objetivo principal de esta sección corresponde a la formulación de métodos de pronóstico espacio-temporales bajo distintos regímenes de viento, que utilizan no sólo la autocorrelación propia de la serie temporal correspondiente al punto más cercano al PER, sino también utilizan la correlación-cruzada entre las series temporales de este punto y los restantes puntos de retícula del dominio, con distintos desfases temporales. De esta manera es posible identificar la ubicación geográfica y el aporte de aquellos predictores que influyen en mejorar la calidad de los pronósticos de intensidad de viento para el punto de retícula más cercano al PER, para distintos plazos de pronóstico y bajo distintos regímenes de viento.

Los métodos de pronóstico de potencia eléctrica a mediano plazo hacen uso de los beneficios de la historia del PER en conjunto con la utilización de MNPT para minimizar los errores del pronóstico de potencia para plazos mayores a 3 hs. Dentro de este contexto se decidió utilizar los pronósticos de viento del modelo WRF y Global Forecast System (GFS) en la formulación de los modelos de pronósticos de potencia eléctrica combinados, a mediano plazo habiendo analizado el desempeño de las distintas configuraciones del modelo WRF en el Capítulo 3.

Se considera que los errores encontrados en este capítulo serán representativos de lo esperado en un contexto operativo de estos modelos para esta región de estudio.

Respecto al segundo objetivo general, en el Capítulo 5 se cambia la región de estudio y se llevan a cabo diversos análisis utilizando una base de datos de más de 300 parques eólicos instalados en territorio danés. El objetivo de este capítulo es la proposición y evaluación de modelos de pronóstico de potencia eléctrica basados en una versión simplificada del modelo WPPT para cada uno de estos sitios. Complementariamente se propone una generalización espacial de los coeficientes de los modelos propuestos con el objeto de estimar estos valores de forma anticipada a la instalación de nuevos parques eólicos, lo que permitiría realizar predicciones más precisas de potencia eléctrica desde el comienzo de operación de nuevos parques, hasta alcanzar un conjunto suficiente de mediciones de potencia eléctrica y pronósticos de viento que permitan calcular los coeficientes específicos de los modelos de pronóstico para estos nuevos sitios.

Dada la variedad de objetivos y metodologías aplicadas en cada uno de los capítulos, se decidió estructurar éstos presentando una introducción específica con los antecedentes más relevantes del tema, la proposición de la metodología para cada objetivo, los resultados obtenidos para cada caso de estudio y las conclusiones que resumen los resultados más importantes encontrados.

Finalmente el Capítulo 6 resume las conclusiones más importantes obtenidas de los análisis realizados en los distintos capítulos.

1.5 Naturaleza del aporte original de la Tesis

En el último tiempo se han realizado grandes avances en el pronóstico de potencia eléctrica por medio de aerogeneradores a nivel mundial. Sin embargo, los estudios previos se han realizado mayormente en países donde la energía eólica representa un porcentaje sustancial dentro de sus capacidades totales de generación de energía, y que poseen características de viento muy diferentes a las halladas en el sur de Sudamérica, i.e, países europeos y EEUU. Este plan de trabajo propone aplicar diversas metodologías testeadas y afianzadas principalmente en países europeos, estudiando y documentando por primera vez los errores encontrados en el noreste de la región patagónica, mundialmente conocida por ser una de las regiones continentales con mayor intensidad de viento, permitiendo comparar estos resultados con otros parques de alrededor del mundo a través de índices estandarizados. Partiendo de la base que se cuenta con una base de datos muy completa y de buena calidad, eso permitirá realizar un análisis minucioso para proponer modelos que se ajusten de la mejor manera posible a las observaciones.

Por otro lado, uno de los potenciales aportes es la posibilidad de documentar aquellas configuraciones del modelo regional WRF que permitan representar de la mejor manera posible la variabilidad regional y local del viento en capas bajas, en las cercanías del PER, intentando descifrar las fuentes de error sistemáticas y corregirlas.

La presente Tesis además abre toda una nueva línea de investigación en Argentina, sentando los primeros pasos en lo que hace al pronóstico de producción eólica para la región.

Respecto a los objetivos relacionados con el trabajo de Dinamarca, la originalidad de las tareas a desarrollar están relacionadas con la documentación de los errores espaciales y temporales de los modelos matemáticos propuestos, siendo una de las bases de datos más completas del mundo. Por otro lado, la posibilidad de estimar los parámetros y las curvas de potencia de un modelo como WPPT para un potencial emplazamiento de nuevo parque eólico dentro de la región continental de Dinamarca, que pueda ser utilizado desde el primer día de operación del mismo y conociendo los errores asociados a esta estimación, es quizá la componente más original del Capítulo 5, siendo una de las características más llamativas de esta metodología la generalidad de su aplicación.

Capítulo 2

Descripción y análisis de la base de datos del Parque Eólico Rawson

En este capítulo se describe la base de datos del Parque Eólico Rawson (PER) y se realiza un análisis de las distintas variables que la componen. Se presenta una climatología básica del viento y la potencia eléctrica, junto al estudio de la variabilidad diurna y estacional de los aerogeneradores que componen el parque eólico y de la torre meteorológica que allí se encuentra instalada.

2.1 Parque Eólico Rawson: Ubicación geográfica y composición

El Parque Eólico Rawson (PER) se encuentra ubicado a la vera de la Ruta Provincial N° 1, aproximadamente 5 km al sur de la localidad de Rawson, en la provincia de Chubut.

Actualmente es el parque eólico más grande de la Argentina con una capacidad total instalada de 77.4 MW distribuida en 43 aerogeneradores Vestas V90 de 1.8 MW de potencia cada uno. La altura del eje de rotación de cada aerogenerador es de 80m, y el diámetro de las palas contabiliza unos 90m.

Se espera que el PER produzca anualmente 255 GWh de energía, capaz de proveer electricidad a 73.276 hogares según estimaciones presentadas al Ministerio de Economía [1].

La ubicación del PER y su cercanía a las localidades de Rawson y Playa Unión, junto con la presencia de algunos accidentes geográficos pueden apreciarse en la Figura 2.1.1 y Figura 2.1.2. Complementariamente las Figuras 2.1.3 y 2.1.4 presentan la topografía de la región utilizando la base de datos provenientes del Shuttle Radar Topography Mission (SRTM).




Figura 2.1.1. Ubicación geográfica del PER en un contexto regional.



Figura 2.1.2. Entorno local del PER. Pueden observarse las localidades de Playa Unión y Rawson, como así también la cercanía al Mar Argentino y la desembocadura del Río Chubut. Tomado de Google Earth.




Figura 2.1.3. Topografía en los alrededores del PER. Fuente: SRTM.




Figura 2.1.4. Topografía en los alrededores del PER. Zona ampliada. Fuente: SRTM.

2.2 Descripción de la base de datos

Para el desarrollo de este trabajo de investigación se contó con datos provenientes del PER los cuales fueron suministrados por la Compañía Administradora del Mercado Mayorista Eléctrico S.A (CAMMESA) cuyas funciones principales son el despacho técnico y económico del Sistema Interconectado Nacional (SIN), organizando el abastecimiento de la demanda al mínimo costo compatible con el volumen y la calidad de la oferta energética disponible [2].

Esta base de datos cuenta con más de 2 años de mediciones de potencia eléctrica e intensidad y dirección del viento de cada uno de los 43 aerogeneradores que componen el parque. Sin embargo, para cumplir con los objetivos propuestos en la presente Tesis, se decidió limitar el período de estudio a dos años completos, con fecha de comienzo 02/04/2012.

Las mediciones de viento son realizadas con instrumentos instalados sobre la góndola del generador, detrás de las palas, a una altura de 80m sobre el nivel del suelo. Todas las variables medidas son promediadas y guardadas en intervalos de 10 minutos.

Además de la información de cada uno de los aerogeneradores se contó con datos de presión e intensidad y dirección del viento, provenientes de una torre meteorológica instalada en el predio. Las mediciones de viento fueron realizadas en dos niveles: a 80m y 30m de altura, y la presión a 80m sobre el nivel del suelo. Nuevamente los datos son promediados y guardados en intervalos de 10 minutos.

A pesar de que la información se registraba cada 10 minutos, se decidió realizar promedios horarios centrados en cada hora de forma tal de comparar estos valores con las salidas de los modelos numéricos que se encuentran disponibles cada una hora. De ahora en adelante cada vez que se haga referencia a las series de las variables medidas en el PER, implícitamente quedará sentado que se trata de los datos horarios, a menos que se exprese lo contrario.

El diseño del parque y la ubicación de cada una de las turbinas eólicas junto con la posición de la torre meteorológica puede observarse en la Figura 2.2.1. Se puede caracterizar al PER con un diseño compuesto por cuatro filas de aerogeneradores compuestas por 9, 8, 12 y 14 turbinas, con una fuerte orientación norte-sur.

Complementariamente se dispuso de información sobre la disponibilidad de cada aerogenerador para cada intervalo de mediciones de 10 minutos. La misma indica la cantidad de segundos que la turbina eólica estuvo en funcionamiento. Una disponibilidad de 600 segundos equivale a una operación normal de aerogenerador, para ese intervalo de tiempo.

Luego de aplicar filtros básicos de consistencia de datos, la completitud de las series temporales supera el 93% para todas las variables dentro el período de estudio. Como ejemplo la Figura 2.2.2 muestra la completitud de los datos de intensidad de viento de cada uno de los 43 aerogeneradores.




Figura 2.2.1. Diseño del PER. Localización y numeración de los aerogeneradores y ubicación de la torre meteorológica.




Figura 2.2.2. Completitud en [%] de datos de intensidad de viento para cada aerogenerador (WT) que compone el PER. En rojo el valor promedio para el parque eólico.

A modo ilustrativo y para empezar a visualizar el comportamiento de los datos con los que vamos a trabajar, la Figura 2.2.3 muestra las series temporales de potencia eléctrica e intensidad y dirección del viento del aerogenerador número 2 para los dos años tomados en este estudio.

Tres rápidas características se desprenden de esta figura.

- i) Tanto la potencia eléctrica como la dirección del viento son variables acotadas inferior y superiormente.
- ii) Todas las variables poseen una variabilidad de alta frecuencia bien marcada.

iii) Existe algún inconveniente al final de la serie, período en el cuál, luego de aplicar los filtros de consistencia, se ha descartado un conjunto de datos en cada una de las variables medidas en esa turbina.

Si bien a simple vista parece ser que todas las variables son definidas positivas, esto no se cumple estrictamente para la potencia eléctrica. Cuando la intensidad del viento no supera un cierto valor mínimo, que para el caso particular del aerogenerador Vestas V90 es de 3 m/s, la turbina no produce energía y por el contrario, consume leve cantidad de ella para mantener la estabilidad de la red eléctrica.




Figura 2.2.3. Series temporales de: a) potencia eléctrica, b) velocidad del viento y c) dirección del viento para el aerogenerador número 2 (WTN2), y para los dos años de datos.

2.3 Variabilidad espacial en la escala del parque

Si bien el PER abarca un área relativamente pequeña de aproximadamente 25km^2 , es de esperar encontrar dentro del mismo variaciones espaciales en los valores de las variables allí medidas. Además de los procesos naturales que pueden modificar el flujo de aire como cambios en la topografía y rugosidad del terreno, tal como se describe en el trabajo de Hedegaard y Larsen, (1983) y la cercanía a la costa, entre otros factores; la propia presencia de los aerogeneradores modifica sustancialmente el viento disminuyendo su velocidad y aumentando la turbulencia corriente abajo de las turbinas. Este fenómeno conocido como “Efecto Estela” puede producir grandes pérdidas de energía dependiendo del diseño espacial

del parque eólico en consideración. La Figura 2.3.1 muestra la manifestación visual de este fenómeno, para el parque offshore Horns Rev instalado en Dinamarca y cuya explicación está detallada en Bay Hasager y otros, (2013).



Figura 2.3.1. Turbulencia manifestada a través de la nubosidad para el parque eólico offshore Horns Rev instalado al oeste de Dinamarca. Tomada de [4]. Crédito Vattenfall. Fotógrafo: Christian Steiness.

La Figura 2.3.2 muestra la velocidad media y el desvío estándar del viento para la torre meteorológica y cada uno de los aerogeneradores que componen el Parque Eólico Rawson. La misma evidencia la fuerte variación del viento en la escala espacial del parque eólico. El rango de valores de velocidad media del viento es de [7.2, 9.2] m/s, mientras que el desvío estándar cubre un rango de [3.3, 4.2] m/s. Las turbinas eólicas instaladas al oeste del PER y al sur de cada fila poseen velocidades medias y desvíos estándar superiores al resto de los aerogeneradores, mientras que los aerogeneradores instalados en el centro de la tercer fila y el norte de la cuarta muestran los valores más bajos.




Figura 2.3.2. Cuartiles de velocidad media y desvío estándar del viento para cada aerogenerador y torre meteorológica.

Análogamente se realizó el mismo análisis para la potencia eléctrica. La Figura 2.3.3 muestra la variación espacial de la potencia eléctrica media y el desvío estándar. En este caso obtenemos una distribución espacial similar aunque aparecen leves diferencias respecto a la Figura 2.3.2. Si bien la potencia eléctrica es función de la velocidad del viento, su dependencia no es lineal, con lo cual no es posible trasladar los valores de intensidad media del viento a potencia eléctrica media, debiéndose tener en cuenta la distribución de velocidades, lo que explica las pequeñas diferencias encontradas entre ambas figuras. El rango de potencia media y desvío estándar es de [750, 1000] KW, y [610, 650] KW respectivamente. Este resultado pone de manifiesto la gran dificultad que subyace en la incorporación de un recurso tan fuertemente variable en una matriz energética.








Figura 2.3.3. Cuartiles de potencia eléctrica media y desvío estándar de la potencia para cada aerogenerador.

La Figura 2.3.4 muestra la variación espacial de la velocidad media de cada aerogenerador según la dirección predominante del viento, dividido en ocho sectores principales (N, NE, E, SE, S, SO, O y NO). En este caso se optó por elegir los datos de dirección del viento en la torre meteorológica como valor de referencia para realizar este análisis. De lo contrario se podrían obtener resultados no consistentes por el hecho de estar promediando distintas muestras para cada aerogenerador dado que también existen variaciones de la dirección del viento dentro del parque eólico.



1.. Cuartil 2.. Cuartil 3.. Cuartil 4.. Cuartil






Figura 2.3.4. Cuartiles de velocidad media y desvío estándar del viento de cada aerogenerador y torre meteorológica, para cada uno de los 8 sectores principales de dirección del viento.

En términos generales, a medida que la dirección predominante del viento va rotando, los aerogeneradores ubicados corriente arriba poseen mayores velocidades respecto a los que se encuentran corriente abajo, debido, entre otros factores, al efecto estela mencionado anteriormente. Sin embargo hay aerogeneradores ubicados al sur de las 4 filas, como el WT30, WT31, WT32 y WT33, que poseen altos valores de velocidad media independientemente del sector donde sople el viento. Más adelante veremos que la dirección de los vientos en éstos es diferente al de la mayoría de los aerogeneradores, con una fuerte componente sudoeste del viento. Debido a que en este análisis se utilizó como referencia la dirección del viento de la torre meteorológica localizada en la sección noroeste del PER, la misma puede no ser representativa de lo que acontece en estos aerogeneradores.

En resumen, las figuras descritas en la presente sección muestran la complejidad que adquiere la descripción del flujo de aire en la escala espacial del parque eólico, encontrando diferencias de hasta 2 m/s en la velocidad media del viento, y diferencias mayores a 240 KW de potencia eléctrica media entre aerogeneradores. Asimismo los aerogeneradores cuyas velocidades medias se encuentran entre el tercer y cuarto cuartil, poseen mayores desvíos estándar para ambas variables analizadas.

2.4 Análisis de las series temporales: Variabilidad diurna y estacional del viento

En esta sección se realizará un análisis del ciclo diurno medio de la dirección y velocidad del viento para la Torre Meteorológica (TM), y para el conjunto de aerogeneradores que componen el PER, mientras que en la siguiente sección se analizará análogamente la evolución horaria media de la potencia eléctrica para cada aerogenerador.

En primera instancia y antes de comenzar el análisis se comparó el comportamiento medio del parque eólico con respecto a las mediciones realizadas en la torre meteorológica. La Figura 2.4.1 muestra el gráfico de dispersión de los valores de viento medidos en la TM y los obtenidos a partir de promediar las mediciones de viento en cada aerogenerador del PER. El coeficiente de determinación R^2 entre ambas series es 0.90, indicando una alta correlación entre ambas, además de ser significativa al 99%.




Figura 2.4.1. Diagrama de dispersión del viento medido en la TM y el viento promedio del PER. La línea roja continua indica el ajuste ideal entre ambas series.

Complementariamente la Figura 2.4.2 muestra el Quantile-Quantile plot (Q-Q plot) de las distribuciones de viento de la TM y del PER respectivamente. Nuevamente la línea roja indica el ajuste perfecto, i.e: ambas distribuciones de viento coinciden perfectamente. En este caso la figura evidencia un muy buen ajuste entre ambas distribuciones, aunque el viento medio del PER es superior al de la TM en el rango [0, 3] m/s, mientras que lo opuesto ocurre entre 6 y 14 m/s.




Figura 2.4.2. Q-Q plot entre el viento de la TM y el promedio del PER. La línea roja indica el caso ideal donde ambas distribuciones coinciden.

Considerando que la intensidad del viento en la TM tiene un comportamiento similar a las mediciones promediadas del PER, el siguiente análisis sobre la distribución del viento y su ciclo medio se formuló en base a la serie de datos de la torre.

El panel izquierdo de la Figura 2.4.3 muestra el histograma de probabilidades (barras color verde) y su ajuste a través de una distribución de Weibull (línea continua color rojo). Si bien no se hizo una evaluación del ajuste, es evidente el buen acompañamiento de la distribución teórica al histograma. El panel derecho de la figura muestra en líneas negras entrecortadas los diferentes ajustes de Weibull para cada uno de los 43 aerogeneradores del parque eólico, y para la torre meteorológica en línea roja continua. Complementando el análisis de la Sección 2.3 en el cual se discutió la variabilidad espacial de la velocidad media entre aerogeneradores, queda claro a partir de la Figura 2.4.3 que también existe una variabilidad espacial de las distribuciones de viento asociadas a cada turbina, no sólo con modificaciones en el valor medio, sino también en la varianza.

La Figura 2.4.4 muestra el ciclo medio diario de la velocidad del viento considerando los dos años de mediciones. En la misma se observan dos máximos de viento: Un máximo relativo centrado alrededor de las 6 de la mañana y el máximo absoluto que ocurre durante la tarde entre las 15 y 16 hs (Hora Local). El ciclo diario del desvío estándar muestra en cambio un máximo en las horas matinales, entre las 9 y 12hs, y prácticamente posee valores superiores a 3.5 m/s en todos los tiempos.




Figura 2.4.3. Panel izquierdo: Histograma de frecuencias y ajuste de Weibull para la TM. Panel derecho: Ajustes de Weibull para los 43 aerogeneradores del PER en líneas negras entrecortadas y la TM en línea roja continua.




Figura 2.4.4. Ciclo medio diario de la velocidad del viento y desvío estándar para la torre meteorológica. Las horas del día se encuentran expresadas en la Hora Oficial Argentina (HOA).

El ciclo diario de la velocidad media del viento y el desvío estándar para las 4 estaciones del año se observa en las Figuras 2.4.5 y 2.4.6. En la estación estival se maximiza la amplitud diaria de intensidad de viento, alcanzando valores máximos en horas de la tarde, alrededor de las 17 hs y valores mínimos durante la noche. La amplitud va atenuándose en el otoño para prácticamente desaparecer en el invierno donde predominan valores elevados de viento durante todo el día, sin distinción de la hora. En primavera vuelve a aparecer la onda diaria bien marcada con una amplitud mayor respecto del otoño.

Respecto del desvío estándar, va retrasándose el momento donde ocurre la máxima variabilidad. En verano ocurre en horas de la mañana, alrededor de las 09hs, mientras que en el otoño y el invierno ocurre a las 12 hs y 13 hs respectivamente. Luego en primavera comienza a adelantarse alcanzando el máximo de variabilidad a las 11 hs. Los valores de desvío estándar son superiores a 3 m/s prácticamente en todos los momentos de cada estación del año.




Figura 2.4.5. Ciclo diario de la velocidad media del viento para cada estación del año utilizando los datos de la torre meteorológica. Las horas del día se encuentran expresadas para la Hora Oficial Argentina (HOA).




Figura 2.4.6. Ciclo diario del desvío estándar del viento para cada estación del año utilizando los datos de la torre meteorológica. Las horas del día se encuentran expresadas para el Huso Horario Argentino (HOA).

Un análisis más detallado de evolución media horaria de la intensidad y dirección del viento para el PER y la TM puede observarse en el panel superior e inferior de la Figura 2.4.7 respectivamente. En el diagrama de la izquierda se encuentra en sombreado la velocidad del

viento en función de la hora del día y de la dirección del viento, y en contornos sólidos las frecuencias de ocurrencia. El gráfico de la derecha muestra los boxplots horarios mostrando el ciclo medio diurno y su variabilidad. En la realización de estas figuras se han utilizado los dos años completos de mediciones, sin distinción en estaciones del año.

Vale la pena destacar un caso atípico correspondiente al aerogenerador número 1. En este caso aparece un corrimiento en dirección horaria de las frecuencias de viento, obteniendo valores máximos de ocurrencia en todo el cuadrante NO. Analizando la rosa de los vientos y la evolución diurna de las frecuencias de viento, se decidió no utilizar la información direccional de ese aerogenerador y se optó por complementar la información de intensidad de viento utilizando la dirección del viento del WT2. Esta decisión se tomó bajo la hipótesis de que el sensor estaría funcionando correctamente, pero con una mala calibración del offset del instrumento dada la sistematicidad de los errores.

Además las series temporales de dirección del viento de los aerogeneradores 31 y 37 fueron sustituidas por las de los aerogeneradores 32 y 38 respectivamente debido al mal funcionamiento de los instrumentos durante los 2 años de mediciones.

La dirección promedio del PER entonces incluye las modificaciones realizadas en la dirección del viento para los 3 aerogeneradores anteriormente mencionados.

Existe una clara correspondencia entre ambos gráficos. El predominio de vientos del sector oeste (270°) aparece tanto en la evolución diaria del viento del PER como en la TM. Asimismo el máximo de intensidad del viento ocurre en el sector OSO a lo largo del día, maximizando en horas de la tarde y centrándose en el sector SO.

Sin embargo en la evolución diaria del viento del PER surge un máximo secundario, con vientos débiles del sector SE centrado a las 18 hs, que no es reflejado en las mediciones de la TM. La línea de costa posee una orientación SO-NE, y parte de la explicación de ocurrencia de vientos de este sector puede estar determinado por el fenómeno de brisa de mar dada la cercanía a la costa. Veremos más adelante, en el análisis estacional del viento, que aumenta la frecuencia e intensidad de los vientos del sector SE en la estación estival.

La Figura 2.4.8 muestra en su panel superior el comportamiento más característico de los aerogeneradores del PER, en este caso se tomó como ejemplo el aerogenerador número 24 (WT24), mientras que el panel inferior muestra la variabilidad diurna característica de los aerogeneradores localizados al sur de las filas, siendo ilustrativo el ejemplo del aerogenerador 30 (WT30). La diferencia más grande es que el WT30 posee la mayor frecuencia de vientos centrada en el sector SO, junto con altos valores de intensidad de viento a lo largo del día. Además, a pesar de que la frecuencia de vientos del sector SE es menor, la intensidad del viento en este sector es mayor con respecto al común de los aerogeneradores. Por último el máximo de intensidad de viento no se expresa en horas de la tarde, sino en horas de la mañana, entre las 06 y 09 horas.




Figura 2.4.7. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el PER (panel superior) y para la TM (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento.

Las figuras 2.4.9, 2.4.10, 2.4.11, y 2.4.12 muestran el ciclo diurno medio de la intensidad del viento para el promedio del PER y la TM en cada una de las cuatro estaciones del año: DEF, MAM, JJA, y SON respectivamente. En la estación estival la mayor frecuencia de viento sucede en el sector OSO, maximizando en horas de la mañana. El máximo de intensidad de viento ocurre en horas de la tarde, alrededor de las 18 hs, en donde adquieren igual frecuencia los vientos provenientes del sector O y SE, aunque la intensidad máxima del viento asociada a la brisa de mar ocurre antes, alrededor de las 15/16 hs, con vientos provenientes del sector ESE. La presencia de la brisa se hace notar entonces tanto en el PER como en la TM, aunque con mayor frecuencia en el PER. Secundariamente aparece otro máximo de intensidad de viento aunque con menor probabilidad de ocurrencia, proveniente del sector NNE en las horas finales del día. El ciclo medio diurno de intensidad de viento tiene una amplitud menos marcada para el PER que para la TM.




Figura 2.4.8. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el aerogenerador 24 (panel superior) y para el 30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento.




Figura 2.4.9. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el PER (panel superior) y para la TM (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre DEF.

El ciclo diurno para el segundo trimestre del año muestra una disminución de la intensidad del viento y un leve corrimiento del flujo al sector ONO. Asimismo el máximo de intensidad de viento ocurre entre las 15 y 18 hs, en el sector OSO, y un máximo relativo de frecuencias aparece en el sector SE al final de la tarde, aunque con menor probabilidad de ocurrencia. Nuevamente el PER muestra un ciclo medio con menor amplitud respecto al de la TM.




Figura 2.4.10. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el PER (panel superior) y para la TM (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre MAM.

Tanto para el PER como para la TM, en la estación invernal (JJA) aumentan considerablemente las frecuencias de viento de todo el sector oeste, reduciéndose al mínimo las frecuencias de vientos del cuadrante Este. El máximo de ocurrencia está centrado en el sector oeste, con mayor ocurrencia en horas de la noche y la mañana. Como en el resto de las estaciones del año, la intensidad máxima está asociada a vientos del sector SO y SSO, maximizando en horas de la tarde. Una característica llamativa es la presencia de un máximo de velocidad de viento correspondiente al sector ESE en horas de la noche observado en la TM, el cual no aparece en el PER. Sin embargo ese máximo relativo posee una frecuencia de ocurrencia muy baja.




Figura 2.4.11. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el PER (panel superior) y para la TM (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre JJA.

En primavera (SON) comienza a aumentar la frecuencia de vientos de sectores del cuadrante Este que prácticamente habían desaparecido en JJA. La intensidad del viento es menor respecto al invierno y comienza a observarse una mayor amplitud del ciclo medio diurno. Las frecuencias máximas de ocurrencia se centran en el sector oeste, siendo más importantes en horas de la mañana. Vuelve a aumentar la frecuencia de vientos del sector SE en horas de la tarde, y aparecen con mayor frecuencia vientos del sector norte en horas de la noche, acompañados de máximos relativos de velocidad que ocurren alrededor de las 18 hs.




Figura 2.4.12. Izquierda) En sombreado la velocidad del viento en función de la hora del día y de la dirección del viento para el PER (panel superior) y para la TM (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre SON.

2.5 Análisis de las series temporales: Variabilidad diurna y estacional de la potencia eléctrica

En esta sección se analizará el ciclo medio diurno y estacional de la potencia eléctrica de forma análoga a lo descrito en la Sección 2.4. Sin embargo algunas diferencias surgen al estudiar el comportamiento de esta variable:

- En primer lugar, dado que el objeto de estudio son las series temporales de potencia eléctrica, no se realizará una comparación con las mediciones de la TM debido a que, por razones obvias, no se mide esta variable en ella.
- En segundo lugar no se estudiará el ciclo diurno de la potencia total del parque eólico ya que sólo alrededor del 50% del tiempo los 43 aerogeneradores están conjuntamente en funcionamiento. Se decidió mostrar en primera instancia los ciclos diurnos medios de la potencia media del PER, calculada a partir del promedio pesado de la potencia eléctrica de cada aerogenerador individual. De

esta manera se tiene una medida representativa de la potencia media del PER considerando la variabilidad interna de esta variable dentro del parque eólico. Complementariamente se realizó el análisis de un aerogenerador representativo del parque, y otro correspondiente a las turbinas que se encuentran al sur de las filas que lo componen.

De forma análoga al análisis realizado en la Sección 2.4, la Figura 2.5.1 muestra el ciclo medio diurno de la potencia eléctrica media del PER (panel superior) y el desvío estándar (panel inferior), habiendo utilizado los dos años de mediciones. Aparece un máximo absoluto alrededor de las 15 horas, y un segundo máximo alrededor de las 6 horas de la mañana. Este comportamiento se observaba también en la Figura 2.4.4, aunque la amplitud del ciclo de la potencia eléctrica media es superior. Esto se debe principalmente a que en el rango de vientos de 3 m/s – 13 m/s la potencia eléctrica es función del cubo de la velocidad del viento. Asimismo los valores elevados del desvío estándar del viento que ocurrían entre las 9 horas y las 12 horas son reflejados también en la potencia eléctrica media del parque.

El análisis estacional muestra también un comportamiento muy similar al observado en la Figura 2.4.5 para la intensidad del viento. Se puede apreciar un ciclo diurno muy marcado en los meses de primavera y verano maximizando la potencia eléctrica en horas de la tarde y minimizando en horas nocturnas, apareciendo un segundo máximo relativo en horas de la mañana. En los meses de otoño la onda diurna va perdiendo amplitud y en términos medios la potencia eléctrica adquiere los valores más bajos respecto de las otras estaciones.

En invierno desaparece la onda diurna y la potencia eléctrica media se mantiene prácticamente constante y con valores elevados para todas las horas del día.




Figura 2.5.1. Ciclo medio diurno de la potencia eléctrica media del PER y desvío estándar. Las horas del día se encuentran expresadas en la Hora Oficial Argentina (HOA).




Figura 2.5.2. Ciclo diario de la potencia eléctrica media del PER para cada estación del año. Las horas del día se encuentran expresadas para la Hora Oficial Argentina (HOA).

La Figura 2.5.3 muestra la rosa de potencia eléctrica para el aerogenerador 24 (izquierda), ubicado en el centro del PER y el número 30 (derecha), que se encuentra al sur de la cuarta fila. El último intervalo, de color rojo intenso, corresponde a la potencia máxima alcanzada por la turbina.




Figura 2.5.3. Rosa de potencia eléctrica [MW] para el aerogenerador número 24 (izquierda) y el número 30 (derecha).

Con el objeto de relacionar la potencia eléctrica con la intensidad del viento, la Figura 2.5.4 muestra la rosa de intensidad de viento para los mismos aerogeneradores. Los valores escogidos para los intervalos de viento están relacionados con el comportamiento de la potencia eléctrica producida por el aerogenerador Vestas V90 según el rango de valores de

viento medidos. Para un mayor entendimiento en la Sección 2.6 se describe en detalle la relación intrínseca entre la velocidad del viento y la potencia eléctrica.




Figura 2.5.4. Rosa de intensidad de viento [m/s] para el aerogenerador número 24 (izquierda) y el número 30 (derecha).

Anualmente las turbinas poseen una mayor frecuencia de potencias máximas cuando el viento proviene de los sectores OSO y SSO para los aerogeneradores 24 y 30 respectivamente, coincidiendo además con una mayor frecuencia de vientos entre 13 m/s y 25 m/s; rango en el cuál el aerogenerador Vestas V90 adquiere su potencia máxima. Nuevamente vemos la diferencia entre las direcciones prevaecientes para la mayoría de los aerogeneradores con respecto a aquellos que están ubicados al sur de las líneas, apreciando además valores de potencia eléctrica e intensidad de viento promedio considerablemente superiores en el WT30 respecto a WT24.

El ciclo medio diurno de la potencia eléctrica (en sombreado) es mostrado en la Figura 2.5.5. Para el WT24 la potencia eléctrica se maximiza en horas de la tarde, entre las 15 y 18 hs, coincidente con vientos del sector OSO. Para el WT30, el máximo de potencia se alcanza en horas de la noche y principio de la mañana con vientos centrados en el sector SSO-SO. Un segundo máximo relativo ocurre en horas de la tarde también con vientos provenientes del SSO-SO, apareciendo al mismo tiempo pero con menor frecuencia un máximo en el sector SE, asociado al fenómeno de la brisa ya descrito anteriormente en la Sección 2.4.




Figura 2.5.5. Izquierda) En sombreado la potencia eléctrica en función de la hora del día y de la dirección del viento para WT24 (panel superior) y WT30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento.

Las figuras 2.5.6, 2.5.7, 2.5.8 y 2.5.9 muestran el ciclo diurno medio de la potencia eléctrica para ambos aerogeneradores en cada una de las cuatro estaciones del año: DEF, MAM, JJA, y SON respectivamente.




Figura 2.5.6. Izquierda) En sombreado la potencia eléctrica en función de la hora del día y de la dirección del viento para WT24 (panel superior) y WT30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre DEF.

En el verano grandes diferencias entre el comportamiento de ambos aerogeneradores son observadas. En el caso del comportamiento típico de los aerogeneradores del PER se observa un máximo de frecuencias de vientos del sector OSO, principalmente en horas de la mañana, mientras que en el caso del WT30 ocurre en el sector SSO. El máximo de potencia ocurre en el primer caso en horas de la tarde, mientras que en el segundo ocurre temprano por la mañana y por la noche antes de culminar el día. Asimismo aparece un máximo relativo de frecuencias de vientos del sector SE para el WT24, mientras que para el WT30 esto ocurre con vientos del sector NE. Sin embargo, dos máximos relativos de potencia eléctrica pueden observarse alrededor de las 18 hs en el sector SE y NNW para el aerogenerador ubicado al sur de la cuarta fila del PER.

Para el otoño las frecuencias del sector SE van disminuyendo para ambos aerogeneradores y se produce un corrimiento hacia el norte de las frecuencias máximas con respecto a la estación estival. Los máximos de potencia eléctrica van disminuyendo intensidad aunque coinciden temporalmente con respecto a DEF. Complementariamente la potencia asociada a vientos de todo el cuadrante este va perdiendo intensidad, disminuyendo también su frecuencia.




Figura 2.5.7. Izquierda) En sombreado la potencia eléctrica en función de la hora del día y de la dirección del viento para WT24 (panel superior) y WT30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre MAM.

Durante los meses de invierno predominan los vientos del cuadrante oeste, prácticamente desapareciendo los vientos del cuadrante este para el WT24. Sin embargo un máximo relativo de frecuencias del sector ESE puede observarse en el WT30, coincidente además con un máximo de potencia eléctrica que ocurre a lo largo del día, maximizando en horas de la mañana y comienzos de la noche. El máximo absoluto sigue ubicándose durante la madrugada para este aerogenerador, y durante la madrugada y temprano por la tarde para el WT24.




Figura 2.5.8. Izquierda) En sombreado la potencia eléctrica en función de la hora del día y de la dirección del viento para WT24 (panel superior) y WT30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre JJA.

Finalmente en primavera comienzan a aumentar las frecuencias de vientos del cuadrante este, y en términos medios hay una disminución generalizada de la potencia eléctrica. Vientos del sector NW y NE comienzan a aumentar su frecuencia y la señal de la brisa bien marcada en horas de la tarde se hace presente para maximizar nuevamente en verano.




Figura 2.5.9. Izquierda) En sombreado la potencia eléctrica en función de la hora del día y de la dirección del viento para WT24 (panel superior) y WT30 (panel inferior). Frecuencia de ocurrencia en contornos sólidos. Derecha). Boxplots horarios de velocidad del viento. Correspondiente al trimestre SON.

2.6 Relación entre la velocidad del viento y la potencia eléctrica: Proposición de distintas curvas de potencia

La curva de potencia de un aerogenerador proporciona una relación intrínseca entre la velocidad del viento y la potencia generada para cada velocidad. Se supone que es una relación única para cada tipo de aerogenerador y representativa para todos los aerogeneradores del mismo tipo. Es decir que una vez homologada la curva de potencia de un modelo de aerogenerador, luego la misma será representativa para todos los aerogeneradores del mismo modelo fabricados posteriormente.

Al diseñarse un aerogenerador se calcula una curva de potencia teórica que luego debe ser homologada in situ a partir de mediciones. El procedimiento es complejo y riguroso, debiéndose cumplir requerimientos internacionales. La norma IEC 61400-12 parte 1 (IEC, 2005) describe el procedimiento a realizar para cada situación.

La primer aproximación y la más simple de ellas es utilizar la curva de potencia suministrada por el fabricante del aerogenerador, que en este caso es la empresa danesa Vestas, en particular la curva correspondiente a su modelo Vestas V90, de 1.8 MW de potencia. Debido a que la potencia del viento es proporcional a la densidad del aire, para la misma velocidad, a mayor densidad del aire, mayor es la potencia del viento. Lo mismo sucede en la curva de potencia del aerogenerador. Es entonces que la empresa proporciona información sobre las curvas de potencia obtenidas para distintos valores de densidad del aire. Este tipo de curvas se ha utilizado por ejemplo en el trabajo de Roulston y otros, (2003).

La Figura 2.6.1 muestra la curva de potencia del aerogenerador Vestas V90 de 1.8 MW para una densidad del aire $\rho = 1.225 \text{ kg/m}^3$.




Figura 2.6.1. Curva de potencia del aerogenerador Vestas V90 de 1.8 MW de potencia para una densidad del aire de 1.225 kg/m^3 .

En base a la Figura 2.6.1 es posible identificar 4 zonas con comportamientos diferentes a tener en cuenta:

1. Cuando la velocidad es inferior a la de velocidad de cut-in (o velocidad de arranque), el aerogenerador no produce energía. En el caso de este aerogenerador la misma es 3 m/s y considerando la velocidad media del PER tan sólo 6.0% del tiempo el viento estuvo por debajo de este umbral.
2. Cuando la velocidad se encuentra entre la velocidad de cut-in y la velocidad nominal (velocidad a la cual se alcanza la potencia máxima), la curva de potencia es proporcional a la velocidad al cubo. Entonces pequeñas variaciones en el pronóstico de velocidad provocarán grandes cambios en la energía generada. Razón por la cual es una de las zonas más sensibles a errores en el pronóstico de energía. En el caso del PER aproximadamente 85.6% del tiempo el viento sopla dentro de este rango de velocidades.
3. Si la velocidad se encuentra entre la velocidad nominal y la velocidad de cut-out (o velocidad de corte del aerogenerador), la potencia se mantiene al máximo y constante. Debido a su característica de invariabilidad, pequeños errores en el pronóstico de viento, generarán

pequeños errores en producción de energía. En el análisis de la serie del viento promedio del PER esto ocurre tan sólo 8.4% del tiempo.

4. Cuando la velocidad supera la velocidad de cut-out, un abrupto cambio en la potencia del aerogenerador está presente, ya que se pasa de 1800 kW de potencia a 0 kW. Es entonces de vital importancia (debido a esta pérdida de continuidad de potencia generada) tener una buena performance del modelo en el rango de velocidades cercanas a 25 m/s, como lo trata el trabajo de Kay y otros, (2009). Cuando se analizan los datos horarios del PER no hay registro que en una hora completa esto haya sucedido.

Complementariamente en el presente trabajo se propusieron otras dos alternativas para encontrar la relación entre el viento y la potencia eléctrica del PER. La primera de ellas consiste en proponer una función de regresión que explique con un alto grado de precisión la relación existente entre los pares de datos de viento y potencia medidos en cada aerogenerador, para cada uno de los 8 sectores principales de dirección de viento. En ese contexto se propuso la siguiente función de regresión, dentro de la familia de funciones logísticas:

$$P(v) = \frac{P_{max}M_0e^{rv}}{P_{max}+M_0(e^{rv}-1)} \quad \text{Ec. 2.6.1}$$

Donde P y v son la potencia eléctrica y la velocidad del viento medidas cada 10 min en cada aerogenerador, y P_{max} , M_0 , y r , parámetros a determinar a través de cuadrados mínimos para funciones no lineales. En particular se utilizó la función “Non linear Least Squares – (nls)” dentro del entorno de programación de código abierto R, para encontrar los valores de los parámetros que minimizan los residuos al cuadrado. Asimismo la función *nls* posee la flexibilidad de proponer un límite superior a la función de regresión propuesta, lo cual es muy adecuado para nuestro trabajo ya que la potencia eléctrica se encuentra acotada superiormente. Más detalle sobre el análisis de regresión no lineal puede encontrarse en el libro de Bates y Watts, (1988).

Este cálculo se realizó para cada uno de los 43 aerogeneradores y 8 sectores principales de dirección de viento (N, NE, E, SE, S, SO, O, NO, y N), totalizando 344 curvas de potencia.

A modo de ejemplo la Figura 2.6.2 muestra el gráfico de dispersión de la potencia eléctrica y la velocidad del viento cuando el flujo proviene del sector NO, para el WT10. La línea roja continua corresponde a la función de regresión ajustada a ese conjunto de datos.




Figura 2.6.2. Gráfico de dispersión de potencia eléctrica y viento (círculos grises) para el WT10 y sector de viento NO. En línea roja continua está graficada el ajuste a través de una regresión no lineal.

A simple vista vemos que la función propuesta parece ajustar correctamente a las observaciones. La Figura 2.6.3 muestra los boxplots del coeficiente de determinación (R^2) de la potencia medida respecto a la modelada a través de la función de regresión propuesta para cada uno de los 43 aerogeneradores, en función del sector de viento predominante. En todos los casos su valor es superior a 0.975 alcanzando valores superiores a 0.99 cuando el flujo es del sector norte.

La última aproximación es análoga a la anterior con la siguiente diferencia: en vez de utilizar los pares de intensidad de viento y potencia eléctrica medidos en cada aerogenerador, se calcularon las curvas de potencia para cada turbina utilizando la intensidad media del viento en el PER (considerando las 43 turbinas), y la potencia individual de cada aerogenerador. La dependencia direccional de estas curvas fue realizada utilizando la dirección media del viento considerando también todas las máquinas del PER. Luego la potencia total del parque corresponde a la suma de las potencias individuales para cada uno de los 8 sectores principales de viento.

Cabe destacar que esta última aproximación considera implícitamente las variaciones internas del viento en la escala del parque, involucrando de forma muy sencilla las interacciones entre aerogeneradores que dependen fuertemente de la dirección prevaleciente del flujo como hemos visto en la Sección 2.3. Además, si se conoce anticipadamente que un aerogenerador específico estará desconectado, se puede considerar de manera más precisa su aporte con respecto a la potencia total del PER, ya que este aporte depende de la dirección donde proviene el viento.




Figura 2.6.3. Boxplots del coeficiente de determinación entre la potencia medida y la modelada a través de la función de regresión para los 43 aerogeneradores, en función de la dirección predominante del viento.




Figura 2.6.4. Curvas de potencia para cada una de las aproximaciones. En verde las provistas por el fabricante para el aerogenerador Vestas V90 de 1.8 MW, para distintos valores de densidad de aire. En azul las obtenidas a partir de la suma individual de las curvas de potencia de cada aerogenerador, y en rojo las correspondientes a la tercer aproximación propuesta.

Finalmente la Figura 2.6.4 muestra las curvas de potencia obtenidas para cada una de las metodologías propuestas. En color verde se encuentran las curvas de potencias provistas por Vestas, en función de la densidad del aire. En color azul están las curvas de potencia obtenidas a partir de sumar cada curva de potencia individual de los aerogeneradores que componen el PER, y el rango corresponde a las variaciones asociadas a la dirección predominante del viento. Por último en color rojo está el rango de curvas de potencia correspondiente a la tercer aproximación obtenida a partir de utilizar el viento medio del PER y las potencias individuales de cada aerogenerador.

Si bien el gráfico muestra las curvas de potencia hasta 20 m/s, los aerogeneradores siguen produciendo energía a máxima potencia hasta 25 m/s, donde por encima de este valor y para preservar la integridad estructural de la turbina eólica se ubican las palas en bandera frenando el giro de éstas, dejando de producir energía.

Dada la gran correspondencia entre las curvas de potencia obtenidas con la segunda y tercer metodología (curvas azules y rojas respectivamente), y considerando la simpleza de la aplicación de la tercer metodología, la cual a su vez contiene implícitamente información sobre la variabilidad direccional de la potencia dentro del PER, se optó por escoger esta última aproximación para los modelos de pronóstico de potencia eléctrica que se formularán en el siguiente capítulo.

Referencias del Capítulo 2:

[1] Ministerio de Economía,

http://energia3.mecon.gov.ar/contenidos/archivos/Reorganizacion/renovables/fichas_plantas/pe_rawson.pdf

[2] Cámara Argentina del Mercado Mayorista Eléctrico, S.A. www.cammesa.com.ar

Bates, D.M. and Watts, D.G. Nonlinear Regression Analysis and its Applications. Wiley, 1988.

Bay Hasager, C., Rasmussen, L., Peña, A., Jensen, L.E., y Réthoré, P.E. Wind Farm Wake: The Horns Rev Photo Case. *Energies*, 2013, Vol 6, 696-716.

Hedegaard, K., y Larsen, S.E. Wind Speed and Direction Changes due to Terrain Effects revealed by Climatological Data from two Sites in Jutland. *Reporte Interno RISØ. R-434.*, 1983, pp: 122.

IEC. IEC 61400-12 Wind Turbine Generator Systems – Part 12-1: Power performance measurements of electricity producing wind turbines. International Standard. Geneva - Switzerland, 2005, 1 ed., 90 p.

Kay, M. N., Cutler, A, Micolich, I, MacGill, H, Outhred. Emerging challenges in wind energy. *Australian Meteorological and Oceanographic Journal*. 2009, Vol 58, 99-106.

Roulston MS, Kaplan DT, Hardenberg J and Smith LA. Using medium-range weather forecasts to improve the value of wind energy production. *Renewable Energy*, 2003;28:585-602.

Capítulo 3

Evaluación del pronóstico de viento para distintas configuraciones del modelo WRF

En este capítulo se proponen y evalúan distintas configuraciones del modelo Weather Research and Forecast (WRF) en alta resolución espacial, modificándose aquellas parametrizaciones que puedan modificar sustancialmente la representación del flujo de aire en capas bajas. En particular se evalúa el desempeño del modelo bajo distintas parametrizaciones de capa superficial y capa límite, para las estaciones estival e invernal. Finalmente se analizan los errores de estas simulaciones para distintos regímenes de estabilidad y plazos de pronóstico, analizando su ciclo diario, intentando identificar sus componentes sistemáticas y no sistemáticas.

3.1 Introducción y motivación

Desde la aparición de los Modelos Numéricos de Predicción del Tiempo (MNPT) hasta la actualidad, una diversa cantidad de aplicaciones se han desarrollado en torno a éstos. La industria eólica ha aprovechado y acompañado estos avances focalizándose en la predicción del viento y otras variables secundarias que impactan en la potencia eléctrica como la presión, humedad y temperatura en las capas más bajas de la atmósfera. Los MNPT se han implementado, por ejemplo, para el análisis del recurso eólico a escala regional como en el trabajo MMI, (2012), a escala nacional, Hahmann y otros, (2015) e incluso mundial (<http://globalwindatlas.com/methods.html>). Típicamente los mapas realizados a través de diversas metodologías otorgan información de las distribuciones de intensidad de viento, dirección y densidad de potencia eléctrica a diferentes alturas, con una resolución espacial del orden de decenas de metros. En todos los casos se suele utilizar datos de reanálisis para nutrir los modelos de mesoescala, permitiendo aumentar la resolución espacial en el área de interés a través de un downscaling dinámico, y a su vez los campos de viento producidos en mayor resolución nutren a modelos de microescala simplificados que dan aún más detalle de las variaciones espaciales de viento. Estos últimos representan la variación del perfil de viento debido a cambios locales en la topografía, rugosidad del terreno y presencia de obstáculos en la región. A modo de ejemplo, uno de los modelos comerciales de microescala más utilizados en la industria eólica para estos fines es WAsP (Wind Atlas Analysis and Application Program), y cuyos fundamentos físicos se encuentran explicados en Mortensen, (2015).

Otra de las aplicaciones más destacadas de los MNPT en la industria eólica está relacionada con la realización de pronósticos de potencia eléctrica para plazos temporales del orden de horas a días. Si bien en el Capítulo 4 se abarcará esta temática con mayor profundidad, cabe destacar en esta sección la importancia que adquiere la implementación de los MNPT en la mejora del desempeño de los modelos de pronóstico de potencia eléctrica para plazos superiores a 3-6 hs, resultando ser muy útiles para tomar decisiones a nivel del sistema eléctrico y programar tareas de mantenimiento del parque.

En las últimas décadas se ha trabajado intensamente en la utilización y evaluación de MNPT para fines de pronóstico de potencia eléctrica por medio de aerogeneradores entre los cuales podemos destacar el informe realizado por Giebel y otros, (2011) que realiza una revisión completa del estado del arte en cuanto al pronóstico de potencia eléctrica se refiere. Asimismo, a modo de ejemplo entre un gran número de trabajos relacionados con esta temática, podemos citar los trabajos de Pinson y Hagedorn, (2011); Storm y otros, (2009) y Cutler y otros, (2009), en los cuales se evalúan distintos MNPT en la representación del viento, descripción de Jets de capas bajas, y el desempeño de éstos para predecir rápidos cambios en la producción de energía debido a factores meteorológicos. Normalmente la utilización de los MNPT requiere de un ajuste estadístico de las variables pronosticadas previos a su implementación, comparando los campos simulados con datos históricos observados para mejorar la calidad de los pronósticos, corrigiendo de esta forma los errores sistemáticos que puedan presentarse, como se desarrolla en el trabajo de Reid y Turner, (2001).

Diversos autores han evaluado los errores de los pronósticos de viento para distintas configuraciones de modelos numéricos en distintas regiones del mundo. Algunos de estos trabajos evaluaron el impacto de la modificación de la resolución espacial y vertical del modelo como en Rife y Davis, (2005), testearon distintos conjuntos de parametrizaciones Carvalho y otros, (2014) y Dierer y otros, (2005), y describieron los errores encontrados para distintos regímenes de estabilidad, como el trabajo de Sood y otros, (2006). En particular en los trabajos Carvalho y otros, (2014) y en Draxl y otros, (2014), se evaluó el desempeño del modelo WRF configurado con distintas parametrizaciones de capa límite, comparando las simulaciones con datos provenientes de estaciones meteorológicas en tierra y sobre el océano.

Enmarcado en este contexto en este capítulo se proponen y evalúan distintas configuraciones del modelo WRF para el pronóstico de viento en capas bajas en los alrededores del PER para las estaciones estival e invernal calculando y analizando distintos índices de error para la velocidad y dirección del viento. Los índices de error encontrados en otros trabajos se compararán con los resultados obtenidos para esta región del mundo, intentando identificar sus componentes sistemáticas y no sistemáticas.

Cabe destacar la importancia de estudiar y documentar la magnitud de los errores encontrados en los alrededores del PER, ya que los modelos de pronóstico de potencia eléctrica que serán formulados en el Capítulo 4 se basan fuertemente en los pronósticos de viento generados con el WRF.

3.2 Descripción de las simulaciones

3.2.1 Modelo WRF

El modelo Weather Research and Forecast (WRF) es un modelo numérico de mesoescala desarrollado conjuntamente por distintos institutos estadounidenses entre los que se destacan National Center for Atmospheric Research (NCAR), Mesoscale and Microscale Meteorology (MMM), división perteneciente a National Oceanic and Atmospheric Administration (NOAA), National Center for Environmental Prediction (NCEP), Earth System Research Laboratory (ESRL), entre otros., y además cuenta con la colaboración de científicos de distintas universidades.

WRF ha sido diseñado para investigación, educación, y aplicaciones operativas. Su característica de código abierto conjuntamente con la participación de una gran comunidad de científicos y usuarios que lo integran, posibilitan la continua actualización del modelo.

El modelo WRF posee dos núcleos separados; el NMM (Nonhydrostatic Mesoscale Model) y el ARW (Advanced Research WRF). Cada uno de estos núcleos posee un desarrollo diferente en la forma de resolver las ecuaciones que gobiernan la atmósfera como así también la proposición de distintas retículas. El usuario debe escoger el núcleo con el que desea trabajar, y en particular en la presente tesis se decidió optar por el ARW debido a la experiencia previa trabajando con este núcleo adquirida en el Centro de Investigaciones del Mar y la Atmósfera (CIMA), y en particular en trabajos previos realizados con este modelo entre los cuales podemos destacar el de Ruiz y otros, (2010) y la Tesis de Licenciatura de Waimann, (2011).

Complementariamente al núcleo escogido para resolver las ecuaciones de la atmósfera, WRF cuenta con un módulo de pre procesamiento de la información (WPS), incluye además un módulo de asimilación de datos (WRF-VAR), un módulo para resolver la química de la atmósfera (WRF-CHEM) y un módulo de pos procesamiento de los campos resultantes (ARW-POST). No todas ellas serán empleadas en esta tesis, sólo las sustantivas para poder realizar los experimentos y configurar un sistema operativo para los fines de este estudio. La física del modelo está representada a partir de un conjunto de parametrizaciones para representar y explicar distintos procesos que no pueden resolverse explícitamente con la resolución espacial y temporal con la que el modelo resuelve las ecuaciones que gobiernan la atmósfera. Entre las parametrizaciones más importantes para los pronósticos de viento cerca de superficie podemos contar la que representa el intercambio de calor y cantidad de movimiento entre la atmósfera y la superficie y la parametrización que representa los efectos de la turbulencia sobre las variables meteorológicas cerca de la superficie. Las parametrizaciones de estos procesos están en continuo desarrollo y sus mejoras son incorporadas en las sucesivas versiones del modelo. La elección final del conjunto de parametrizaciones a utilizar depende del problema que se intenta resolver, la ubicación y tamaño de la región de estudio y la resolución espacial de la retícula. Aún con todas estas consideraciones es muy difícil encontrar un conjunto de parametrizaciones que se desempeñen mejor en todos los casos posibles. En el trabajo de Ruiz y otros, (2010) se discute la dificultad de encontrar un único conjunto de parametrizaciones que genere los mejores resultados de manera integral, es decir para las distintas variables meteorológicas analizadas y para cada región del dominio de las

simulaciones. Asimismo recomiendan la realización de pronósticos por ensambles para plazos mayores a 1 día.

La Figura 3.2.1.1, muestra la arquitectura del WRF. Más detalle sobre la formulación y descripción técnica del ARW puede encontrarse en Skamarock y otros, (2008). Complementariamente un manual del modelo WRF para los usuarios se encuentra disponible en el siguiente Link:

http://www2.mmm.ucar.edu/wrf/users/docs/user_guide_V3.6/contents.html.

En la presente tesis se implementaron los módulos de pre procesamiento (WPS) para poder utilizar datos de los modelos globales provistos por el NCEP como condiciones iniciales y de borde para los pronósticos locales de viento. Para realizar los pronósticos se utilizó el módulo de resolución de las ecuaciones ARW. Se utilizó la última versión disponible (V3.6), tanto para el WPS como para el ARW.




Figura 3.2.1.1. Componentes del modelo WRF. Imagen tomada de Skamarock, (2008).

3.2.2 Descripción general de las simulaciones: Selección de casos, condiciones iniciales y condiciones de borde

Con el objeto de evaluar el desempeño del modelo WRF bajo distintas configuraciones, se decidió realizar 45 simulaciones en la estación estival e invernal, proponiendo 5 configuraciones distintas del modelo, con modificaciones asociadas a la resolución horizontal y las parametrizaciones de capa límite y capa superficial.

La longitud de las simulaciones fue de 72 hs para 4 configuraciones con mayor resolución espacial, y 48 horas para la restante, con campos de salida horarios. La configuración del WRF con menor resolución espacial y menor plazo de pronóstico (48 hs) fue propuesta además para cubrir otro uno de los objetivos de la presente tesis, asociado a la formulación de modelos combinados de pronóstico de potencia, como se verá en la Sección 4.4, y para el cual fue

necesario realizar 730 ciclos de pronóstico (1 para cada día). Es por razones de costo computacional que el plazo de pronóstico para esta configuración se redujo a 2/3 con respecto a las cuatro restantes.

En relación a la selección de casos y debido al gran costo computacional de las simulaciones se optó por realizar 45 simulaciones en el trimestre de verano (DEF) e invierno (JJA), inicializando los pronósticos a las 12 UTC cada 2 días. Se utilizó el trimestre DEF correspondiente a Diciembre 2012, Enero 2013 y Febrero 2013, y el trimestre JJA correspondiente al año 2013. La proposición de casos solo en la estación invernal y estival se debe a que al analizar los ciclos medios diurnos en cada estación del año, la mayor diferencia entre los regímenes de viento se observa en estas estaciones, en las cuales la amplitud diaria maximiza en el trimestre DEF, mientras que desaparece por completo en el trimestre JJA. Además los procesos locales como la brisa de mar aparecen con mayor frecuencia en las observaciones del PER durante DEF, siendo prácticamente nulas en JJA. Se consideró además que el número de situaciones es suficiente y representativo para analizar y comparar el desempeño del modelo WRF comparando sus pronósticos con las observaciones de viento del PER, aunque no se descarta la conveniencia de contar con más casos para darle mayor robustez al análisis.

Se utilizaron como condiciones iniciales y de borde los pronósticos del modelo Global Forecast System (GFS), de 0.5° de espaciamiento horizontal y disponible cada 3 horas. Los pronósticos del GFS fueron propuestos además como una sexta configuración que sirve de referencia para analizar el beneficio de la implementación de modelos atmosféricos regionales.

Las características técnicas completas, el análisis de los errores para diferentes variables, alturas y plazos de pronóstico, la comparación de su desempeño con respecto a otros modelos globales y más información sobre el modelo GFS puede encontrarse en la página oficial de sus desarrolladores y sus links asociados:

(http://nomads.ncep.noaa.gov/txt_descriptions/GFS_half_degree_doc.shtml).

3.2.3 Selección de los dominios, proyección y resolución de las retículas

Se configuró el modelo WRF de 5 modos distintos. Cuatro configuraciones poseen el mismo dominio, con un espaciamiento horizontal de 5 km (de ahora en adelante llamado dominio *D-AR*), mientras que la quinta configuración tiene un dominio levemente diferente y un espaciamiento horizontal de 10 km (*D-BR*).

Uno de los motivos por los cuales se decidió proponer dos resoluciones espaciales diferentes radica en la posibilidad de comparar la dependencia de la representación del viento en capas bajas al disminuir la distancia entre puntos de retícula, entendiendo que al hacerlo, por ejemplo, es posible determinar de manera más precisa la línea de costa y los efectos locales asociados a la presencia del mar. Es entonces que una de las configuraciones en alta resolución es idéntica a la configuración en baja resolución, a excepción justamente de la resolución espacial escogida. Por otro lado en la bibliografía no resulta del todo evidente la elección de la resolución óptima para obtener mejores resultados. El diseño experimental de dos dominios muy similares a excepción de la resolución espacial es justificado a partir de

estos argumentos, y permitirá analizar el impacto que tiene esta variable en la representación del viento en capas bajas.

La Figura 3.2.3.1 muestra el dominio D-AR mientras que la Figura 3.2.3.2 muestra el dominio D-BR. El dominio D-BR se encuentra levemente alargado en su dirección norte-sur respecto al D-AR.




Figura 3.2.3.1. Dominio propuesto para las cuatro configuraciones en alta resolución (D-AR). El punto negro representa la ubicación geográfica del PER.




Figura 3.2.3.2. Dominio propuesto para la configuración en baja resolución (D-BR). El punto negro representa la ubicación geográfica del PER.

Ambos dominios poseen una proyección cartográfica Lambert Conformal y no tienen anidados. Es decir que a partir de las condiciones iniciales y de borde del modelo GFS se pasa al dominio del WRF a 5 km de espaciamiento horizontal para el dominio D-AR y 10 km para el D-BR. Si bien dentro de las recomendaciones para el uso del WRF se propone una relación 3:1 entre la

resolución de los dominios, en este caso se decidió tener un mayor número de puntos de retícula con una resolución superior, en vez de optar por la realización de anidados. Existen experiencias previas en las cuales la relación entre el distanciamiento horizontal de las condiciones de borde y las del modelo regional han sido superiores a 10:1, como en el proyecto CHUVA (Matsudo y otros, 2013), en el cual 3 de 7 corridas propuestas poseen esta relación entre dominios y presentaron resultados más satisfactorios que aquellos en los que se efectúan anidados múltiples.

La Tabla 3.2.3.1 resume las características de los dominios propuestos.

Dominio	Dist. Entre puntos de retícula	# Puntos este-oeste	# Puntos norte-sur	Topografía utilizada	Proyección	Paso de tiempo
D-AR	5 km	291	291	30 arcseg	Lambert	30 seg
D-BR	10 km	151	171	30 arcseg	Lambert	60 seg

Tabla 3.2.3.1. Características de los dominios D-AR y D-BR.

Considerando que todas las simulaciones contaron con 50 niveles verticales cuya elección será detallada en la Sección 3.2.4, la totalidad de puntos donde el modelo debe realizar sus cálculos es de 4.234.050 en el dominio D-AR, mientras que el número de puntos es considerablemente menor para el dominio D-BR, totalizando 1.291.050. Al aumentar la resolución horizontal un factor 2, el paso del tiempo del modelo se reduce a la mitad para evitar que el modelo WRF no pierda estabilidad numérica. Siguiendo el manual del usuario del WRF, se recomienda que el paso de tiempo de integración del modelo en segundos, sea igual a $6 \cdot \Delta x$ (km). Para las simulaciones en alta resolución esto resulta en un paso de tiempo de 30 segundos ($6 \cdot 5$ km), mientras que para las simulaciones en baja resolución el mismo adquiere un valor de 60 segundos. Esto implica que, por ejemplo, para simulaciones con plazos de pronóstico de 48 hs, el número de cálculos que debe resolver el WRF en todo el dominio es de 24.388.128.000 para el dominio D-AR, y 3.718.224.000 para el dominio D-BR; es decir, 8 veces más.

Se utilizaron los pronósticos de viento del punto de retícula más cercano al PER para el dominio D-AR, D-BR y la retícula de GFS. La Figura 3.2.3.3 muestra la localización del PER y de los puntos más cercanos al parque eólico, mientras que la Figura 3.2.3.4 presenta una imagen ampliada de la región para una mejor visualización de los puntos delimitada por el polígono azul de la Figura 3.2.3.3.




Figura 3.2.3.3. Ubicación geográfica del PER, y de los puntos de retícula más cercanos a éste, para los dominios D-AR, D-BR y GFS.

Si bien se utilizó la misma base de datos de topografía para ambos dominios, la altura del terreno para el punto de retícula más cercano al PER es de 48.3m y 80.6m para las simulaciones en alta y baja resolución respectivamente. Dada la lejanía del punto de GFS y el rápido crecimiento de la topografía en esta región, la altura de este punto es de 147m sobre el nivel del mar.

El valor promedio de altura del terreno dentro del PER es de alrededor de 50m, aunque en el sector sudeste la altura supera los 80m, y la sección norte adquiere valores cercanos a los 25m sobre el nivel del mar (Fuente: Google Maps).




Figura 3.2.3.4. Región ampliada: ubicación geográfica del PER, y de los puntos de retícula más cercanos a éste, para los dominios D-AR, D-BR y GFS.

3.2.4 Niveles verticales

El modelo WRF-ARW posee la coordenada vertical híbrida *sigma-p*, la cual está definida según la Ec. 3.2.4.1.

$$\sigma_k = \frac{(p_k - p_i)}{\pi} \quad \text{Ec. 3.2.4.1}$$

Donde p_i es la presión de un nivel “interfase” cercano a la tropopausa, p_k es la presión en el nivel k y π se define como:

$$\pi = \begin{cases} p_i - p_t, & p_t \leq p \leq p_i \\ p_s - p_t, & p_i < p \leq p_s \end{cases} \quad \text{Ec. 3.2.4.2}$$

Siendo p_s y p_t la presión en la superficie y en el tope de la atmósfera respectivamente. Si se considera $p_i = p_t = \text{cte}$, entonces se obtiene la coordenada sigma estándar.

Esta coordenada posee propiedades de la coordenada vertical sigma en la atmósfera baja (i.e, acompaña los cambios en la topografía y nunca la corta), y propiedades de la coordenada isobárica en niveles altos. La Figura 3.4.2.1 esquematiza la distribución de niveles verticales cuando se utiliza la coordenada *sigma-p*.




Figura 3.4.2.1. Esquemización de niveles verticales con la coordenada σ - p .

En esta tesis se intentó tener una mejor representación de los procesos que se producen cerca de la superficie terrestre, y es por eso que en la elección de los niveles σ - p del modelo se intentó maximizar la cantidad de ellos en capas bajas. Se tomó como referencia la distribución de niveles del modelo WRF que corre operativamente en los servidores del CIMA (wrf.cima.fcen.uba.ar/htm/wrf_out/index_mapas.html), aunque se decidió aumentar la densidad de niveles en los primeros 1000m. La Figura 3.4.2.2 muestra la distribución vertical de los 50 niveles σ - p determinados tanto para las simulaciones en alta resolución (dominio D-AR), como para las de baja resolución (dominio D-BR).




Figura 3.4.2.2. Altura de los 50 niveles σ - p prefijados para las simulaciones en alta y baja resolución.

Para apreciar mejor la cantidad de niveles y las alturas de éstos cerca de la superficie terrestre, la Figura 3.4.2.3 muestra la distribución de las alturas para los primeros 10 niveles verticales. Todos ellos se encuentran por debajo de los 250 m, con 5 niveles por debajo de los 100 m.

Si bien los niveles *sigma-p* varían a lo largo de la simulación en términos medios las alturas de los primeros 5 niveles corresponden a: 0m, 22m, 46m, 58m y 92m sobre el valor que adquiere la topografía del modelo en el punto de retícula más cercano al PER.




Figura 3.4.2.3. Altura de los 10 niveles *sigma-p* prefijados para las simulaciones en alta y baja resolución.

Debe tenerse en cuenta además que el modelo WRF diagnostica a través de su parametrización de Capa Superficial el viento a 10m, aunque éste no pertenece a ningún nivel *sigma-p* en particular.

3.2.5 Selección de las parametrizaciones. Descripción de cada configuración

Parametrizaciones coincidentes en todas las configuraciones

Los experimentos realizados en esta sección de la tesis poseen coincidencias en cuanto a la selección de algunas parametrizaciones que se mantienen fijas en cada una de las 5 configuraciones propuestas, y se describen a continuación.

- a. *Microfísica de nubes*: Esta parametrización controla el tratamiento del agua en sus diferentes fases (vapor, lluvia, gotas de nube, hielo, graupel, etc), y afecta a la física de las nubes. Su influencia en capas bajas está limitada principalmente a áreas cercanas donde exista desarrollo convectivo húmedo. En esta tesis y a pesar del mayor consumo computacional que requiere, se decidió escoger la parametrización WSM6, de 6-clases que diferencia hielo, nieve y graupel, respecto de otras parametrizaciones más simples. Esta parametrización es recomendada para simulaciones en alta resolución. La descripción completa de WSM6 se encuentra explicada en Hong y Lim, (2006).
- b. *Radiación*: Se escogió la parametrización de radiación de onda corta de Dudhia (Dudhia, 1989), y Rapid Radiative Transfer Model (RRTM) para la radiación de onda larga, y que incluye 16 bandas, la interacción con las nubes, el CO₂ y el O₃ Mlawer y otros, (1997). Estas parametrizaciones controlan el balance de energía de radiación de onda corta y larga, e incluyen el rol de las nubes en reflejar, absorber y dispersar

energía en ambas direcciones. Basándose en las recomendaciones para el usuario del WRF, el paso de tiempo en el cuál se llama a estas parametrizaciones es de 5 minutos para las 4 configuraciones en alta resolución, y de 10 minutos para la simulación de baja resolución.

- c. *Convección*: Esta parametrización representa los efectos netos en cuanto a la redistribución de energía, humedad y cantidad de movimiento asociados a la convección cuando los mismos no pueden representarse explícitamente con la resolución horizontal seleccionada. En nuestro caso se decidió utilizar el esquema de Kain-Fritsch (Kain, 2004). La parametrización de convección es llamada en cada paso de tiempo del modelo.
- d. *Suelo*: Se escogió la parametrización de suelo NOAH, la cual incluye una representación del suelo en 4 capas y cuyas variables de pronóstico son la humedad del suelo y la temperatura. Representa los efectos del tipo de suelo en los flujos de calor, contenido de calor y humedad, y evapotranspiración por la vegetación. Complementariamente es la misma parametrización de suelo que utiliza el modelo GFS, que suministra las condiciones iniciales y de contorno al WRF. Más detalle sobre este modelo de suelo puede encontrarse en Chen y Dudhia, (2001).
- e. *Capa superficial*: Esta parametrización especifica cómo la superficie terrestre interactúa con la atmósfera. En esta capa los flujos permanecen constantes con la altura, aunque no así el perfil vertical de las distintas variables de diagnóstico (viento, temperatura, humedad). El esquema de capa superficial queda fijado a partir de la elección de la parametrización de capa límite y es el que determina el valor de viento a 10m.

Parametrización de Capa Límite Atmosférica

Stull (1988), definió la capa límite atmosférica (CLA) como una capa de la tropósfera que está directamente influenciada por la presencia de la superficie terrestre, y responde a los forzantes superficiales en una escala temporal de alrededor de una hora o menos. Esta capa puede alcanzar desde decenas de metros de espesor hasta kilómetros, y su crecimiento diurno está fuertemente ligado a la turbulencia como mecanismo eficiente para el transporte de calor, humedad y cantidad de movimiento. El desarrollo de la capa límite diurna responde principalmente al forzante térmico asociado al flujo de calor sensible, y al forzante dinámico, relacionado con la cortante del viento, el cuál puede jugar un papel muy importante dependiendo de la región de estudio y las características del flujo de aire. En los libros Stull, (1988) y Stensrud, (2004) se encuentra detallada la representación matemática de los procesos turbulentos dentro de la capa límite y su aplicación general en los MNPT.

La parametrización de suelo actúa como condición de contorno de la atmósfera e influencia los flujos de energía que ocurren en la capa superficial de la atmósfera, mientras que las parametrizaciones de capa superficial y capa límite determinan cómo estos flujos influyen la evolución de la capa límite.

Siguiendo el trabajo de Cohen y otro, (2015), las parametrizaciones de capa límite se diferencian principalmente en dos características principales:

- i) *Mezcla local o no-local*: Cuando el esquema de mezcla es local, solamente aquellos niveles verticales que se encuentran adyacentes a un determinado nivel del modelo afectan a ese nivel en particular. Por el contrario, cuando el esquema de mezcla es no-local, múltiples niveles verticales son utilizados para determinar la variación de las distintas variables representadas en la parametrización, en algún determinado nivel. La utilización de esquemas locales poseen una gran desventaja respecto a la representación de la CLA diurna debido a que principalmente la mezcla vertical dentro de ésta ocurre por la presencia de grandes torbellinos (o “*eddies*”) turbulentos, que son mínimamente afectados por variaciones locales en la estabilidad atmosférica, razón por la cual los esquemas no-locales suelen representar mejor aquellos desarrollos profundos de la CLA.
- ii) *Orden de clausura de las ecuaciones turbulentas*: El desarrollo teórico de las ecuaciones de movimiento dentro de la CLA requiere de una descomposición de las distintas variables involucradas en una componente media, que representa el estado medio o básico de la atmósfera, y una perturbación asociada a las fluctuaciones turbulentas. El conjunto final de ecuaciones posee más incógnitas que ecuaciones, y es por eso que se necesita cerrar este sistema de ecuaciones mediante relaciones empíricas, constituyendo la clausura del sistema.

La clausura más sencilla del sistema de ecuaciones es de orden 1, y es también conocida como la teoría K. En esta clausura sólo las ecuaciones de pronóstico de las componentes medias son retenidas y los flujos turbulentos son parametrizados a través de ecuaciones empíricas que relacionan éstos con las variables medias (Stull, 1988).

A medida que el orden de la clausura aumenta, el conjunto de ecuaciones e incógnitas aumenta. En el caso de clausura de orden 1.5, la parametrización incluye no sólo las ecuaciones de pronóstico de las variables medias, sino también se incluye la ecuación de pronóstico de la energía cinética turbulenta media y la de la varianza de las perturbaciones de temperatura potencial. Para la clausura de orden 1 hay cuatro incógnitas que especificar, mientras que en el caso de la clausura de orden 1.5, estas aumentan a 10 incógnitas. Al agregar la ecuación de pronóstico de la energía cinética turbulenta media se provee más información sobre la intensidad y efectividad de la turbulencia dentro de la CLA, permitiendo identificar los aportes térmicos y mecánicos en su generación, y su amortiguación debido a la viscosidad molecular. Además permite mejorar la parametrización de los coeficientes de difusividad turbulenta las cuáles ahora pueden ser funciones de la energía cinética turbulenta y la varianza de las perturbaciones de temperatura potencial, en vez de ser funciones de la cortante media del viento y la estabilidad media de la capa, como en la clausura de orden 1.

Existen incluso clausuras de orden superior, como la de orden 2, en el cuál el número de incógnitas y relaciones empíricas crece sustancialmente, aumentando así la complejidad del sistema.

La Tabla 3.2.5.1 adaptada del trabajo de Cohen y otros, (2015), muestra las características principales de las parametrizaciones de capa límite escogidas para cada una de las 5 configuraciones propuestas. Las primeras 4 configuraciones corresponden a las simulaciones en alta resolución, para el dominio *D-AR*, mientras que la quinta configuración corresponde a la simulación en baja resolución y dominio *D-BR*. Complementariamente se muestran las parametrizaciones de capa superficial asociadas a cada una de las parametrizaciones de capa límite.

Las parametrizaciones seleccionadas en las configuraciones de alta resolución abarcan esquemas de mezcla locales y no locales, como así también distintas formulaciones y órdenes de clausura, permitiendo analizar, por ejemplo, si un esquema local de orden superior presenta un desempeño mejor que uno de formulación más sencilla. Por otro lado la quinta configuración, también llamada “Ctrl” y realizada en baja resolución, presenta las mismas parametrizaciones que la configuración 1 (C1), permitiendo aislar el efecto de la resolución horizontal de las simulaciones.

Vale recordar que la configuración “Ctrl” en baja resolución posee esa denominación ya que fue la que se utilizó en la realización de 730 pronósticos inicializados una vez al día, con plazos de pronóstico de 48 hs, cubriendo así dos años completos de simulaciones. Estos pronósticos son utilizados en la formulación de pronósticos de potencia eléctrica para plazos de hasta 48 hs, como se verá en el Capítulo 4.

Finalmente la Tabla 3.2.5.2 resume todas las características mencionadas en la Sección 3.2, incluyendo las parametrizaciones escogidas, los dominios, espaciamiento entre puntos de retícula, etc.

Configuración	Denominación	Dominio	Parametrización de Capa Superficial	Parametrización de CLA	Mezcla Local/No-Local	Orden de clausura	Descripción
1	C1	D-AR	Esquema de similaridad de Monin-Obukhov, con subcapa viscosa de Carlsol-Boland, y funciones de similaridad estándar.	Yonsei Seul University (YSU). Hon y Pan, (1996).	NO LOCAL	Orden 1.	La parametrización YSU representa explícitamente el entrainment en el tope de la CLA.
2	C2	D-AR	Esquema de similaridad de Monin-Obukhov (Janjic-Eta): Basada en la teoría de similaridad con subcapas viscosas tanto sobre superficies sólidas como sobre cuerpos de agua.	Mellor-Yamada-Janjic (MYJ). Janjic, (1994).	LOCAL	Orden 1.5.	Dada la clausura de orden 1.5, se agrega una ecuación de pronóstico para la energía cinética turbulenta
3	C3	D-AR	Quasi-Normal Scale Elimination PBL (QNSE)	Quasi-Normal Scale Elimination PBL (QNSE). Sukoriansky y otros, (2005).	LOCAL	Orden 1.5.	Similar a MYJ. Intenta resolver ondas dentro de capas estáticamente estables.
4	C4	D-AR	MYNN	Mellor-Yamada-Nakanishi-Niino (MYNN3). Nakanishi y Niino, (2004).	LOCAL	Orden 2.	Comparado con MYJ, las expresiones de estabilidad y longitud de mezcla están basadas en resultados de "Large Eddy Simulations" (LES).
5	Ctrl	D-BR	IDEM C1-AR	IDEM C1-AR	IDEM C1-AR	IDEM C1-AR	IDEM C1-AR

Tabla 3.2.5.1. Selección de parametrizaciones de capa superficial y capa límite para las 5 configuraciones propuestas.

Información sobre el dominio							Parametrizaciones					
Config	Dominio	$\Delta x = \Delta y$	Puntos en x	Puntos y	Proyección	Topografía	Microfísica	Radiación OC/OL	Convección	Suelo	CLA	C. Superficial
C1	D-AR	5 Km	291	291	Lambert	30 arcseg	WSM6	Dudhia/RRTM	Kain-Fritsch	NOAH	YSU	MM5
C2	D-AR	5 Km	291	291	Lambert	30 arcseg	WSM6	Dudhia/RRTM	Kain-Fritsch	NOAH	MYJ	Janjic Eta
C3	D-AR	5 Km	291	291	Lambert	30 arcseg	WSM6	Dudhia/RRTM	Kain-Fritsch	NOAH	QNSE	QNSE
C4	D-AR	5 Km	291	291	Lambert	30 arcseg	WSM6	Dudhia/RRTM	Kain-Fritsch	NOAH	MYNN3	MYNN
Ctrl	D-BR	10 Km	151	171	Lambert	60 arcseg	WSM6	Dudhia/RRTM	Kain-Fritsch	NOAH	YSU	MM5

Tabla 3.2.5.2. Resumen de las características del dominio y las parametrizaciones escogidas para las 5 configuraciones propuestas.

3.2.6 Pronósticos de GFS

Además de las 5 configuraciones propuestas utilizando el modelo WRF, se agrega una sexta configuración basada en los pronósticos del modelo global GFS (de ahora en más llamada “GFS”), y cuya resolución horizontal de los archivos disponibles en su dirección FTP es de 0.5° (aproximadamente 50 km en latitudes medias). Si bien se obtienen los productos con esta resolución, en realidad el modelo de pronóstico se ejecuta en una resolución más alta, de aproximadamente 15 km de distancia entre puntos. En este caso los archivos de pronóstico tienen una frecuencia de 3 horas, con lo cual se aplicó un método de interpolación para completar los datos faltantes y tener la misma respuesta temporal que las otras 5 configuraciones. En particular se utilizó una interpolación por *splines*, proponiendo un polinomio de orden 3 para darle suavidad a la serie interpolada.

Los archivos de pronóstico del modelo GFS poseen información sobre el viento a 10m y 80m sobre el nivel del suelo, y ambas variables fueron utilizadas para la evaluación de los errores de este modelo en la representación del viento en capas bajas alrededor del PER.

3.2.7 Índices de error

Intensidad del viento

Siguiendo el protocolo desarrollado por Madsen y otros, (2005) vamos a definir el error de pronóstico de **velocidad de viento** e_v , como la diferencia entre el valor pronosticado y el observado, para el mismo plazo de pronóstico tal como se muestra en la Ec. 3.2.7.1.

$$e_v(t_0 + k|t_0) = \hat{V}(t_0 + k|t_0) - V(t_0 + k) \quad \text{Ec. 3.2.7.1}$$

Donde $\hat{V}(t_0 + k|t_0)$ es el pronóstico de viento inicializado en el tiempo t_0 , (correspondiente a las 12 UTC en nuestros experimentos), para el plazo de pronóstico k y $V(t_0 + k)$ es el viento horario promedio de los 43 aerogeneradores que integran el PER, para el plazo k . En particular se escogió el punto de retícula del WRF y del GFS, más cercano al centro del PER para ser comparado con las mediciones allí realizadas, corroborando que el punto se encuentre dentro del continente. De aquí en adelante y hasta que se explicita lo contrario, la observación de viento del PER se refiere a la intensidad del viento horaria promedio de los 43 aerogeneradores que miden esta variable a 80m sobre el nivel del suelo.

Se define entonces el error sistemático o BIAS de la intensidad del viento ($BIAS_v$) para cada plazo de pronóstico como el promedio de los errores de pronóstico, como se muestra en la Ec. 3.2.7.2. En este caso e_v^i corresponde a cada error de pronóstico calculado a partir de la Ec. 3.2.7.1 para cada muestra.

$$BIAS_v(k) = \frac{1}{N} \sum_{i=1}^N e_v^i(t_0 + k|t_0) \quad \text{Ec. 3.2.7.2}$$

Como se mencionó anteriormente en este capítulo, es indispensable reducir al mínimo los errores sistemáticos en los pronósticos de viento. Más adelante en esta sección se explicará la metodología utilizada para eliminar estos errores en cada plazo de pronóstico.

Existen otros dos índices característicos para medir el desempeño de los pronósticos de viento que son comúnmente utilizados en la literatura: El Error Absoluto Medio y la Raíz del Error Cuadrático Medio, también conocidos como MAE y RMSE respectivamente por sus siglas en inglés. Las Ec. 3.2.7.3 y 3.2.7.4 los definen para la intensidad del viento.

$$MAE_V(k) = \frac{1}{N} \sum_{i=1}^N |e_v^i(t_0 + k|t_0)| \quad \text{Ec. 3.2.7.3}$$

$$RMSE_V(k) = \sqrt{\frac{1}{N} \sum_{i=1}^N e_v^i e_v^i(t_0 + k|t_0)^2} \quad \text{Ec. 3.2.7.4}$$

Vale destacar que tanto el MAE como el RMSE involucran los errores sistemáticos y los errores no sistemáticos, i.e, aquellos que dada su aleatoriedad no pueden ser eliminados. Sin embargo es posible calcular estos mismos índices una vez eliminado el BIAS en los pronósticos de viento, señalando entonces el impacto que tienen los errores no sistemáticos en el desempeño de los modelos de predicción del tiempo, y los denominaremos *RMSEdb* y *MAEdb*.

Complementariamente se calculó el coeficiente de correlación de Pearson (R) el cual nos da una idea del acompañamiento temporal de las series pronosticadas y observadas, indicando qué porcentaje de la varianza del viento explicada por los pronósticos realizados con los MNPT.

Dirección del viento

Análogamente al RMSE calculado para la intensidad del viento, se propone encontrar índices de error para la dirección del viento. En este caso el error en el pronóstico de dirección de viento (e_{DD}) posee otra formulación y la Ec. 3.2.7.1 se modifica levemente resultando de la siguiente forma:

$$e_{DD}(t_0 + k|t_0) = \min(|\widehat{DD}(t_0 + k|t_0) - DD(t_0 + k)|, 360 - |\widehat{DD}(t_0 + k|t_0) - DD(t_0 + k)|) \quad \text{Ec. 3.2.7.5}$$

Donde $\widehat{DD}$ es el pronóstico de dirección del viento, y DD es la dirección promediada para los 43 aerogeneradores del PER, ambas variables medidas en grados sexagesimales, con precisión decimal, donde 0° corresponde al norte, y aumenta en sentido horario.

Luego los distintos índices de error para la dirección del viento ($BIAS_{DD}$, MAE_{DD} y $RMSE_{DD}$) se calculan siguiendo las Ec. 3.2.7.2, 3.2.7.3 y 3.2.7.4 respectivamente.

Eliminación del BIAS: Validación cruzada

Normalmente es conveniente dividir el período completo de pronósticos/observaciones en dos subconjuntos de datos: un “Período de entrenamiento”, y un “Período de validación”. El primer subconjunto suele involucrar alrededor del 70% del total de datos, y el segundo subconjunto el 30% restante. La idea de esta división es poder entrenar al modelo propuesto y encontrar los errores sistemáticos existentes, para luego ser evaluado en un período independiente. De esta forma se pueden conseguir índices de error más cercanos a los esperados en una aplicación real.

Debido que las muestras experimentales realizadas son pequeñas (45 pronósticos en invierno y 45 en verano), no es posible dividir el conjunto de datos en dos subconjuntos lo

suficientemente grandes como para obtener resultados robustos. Entonces, para corregir los errores sistemáticos se aplicó la metodología Validación Cruzada, en su modo “Leave one out”. Se consideró todo el conjunto de datos, menos una muestra, como período de entrenamiento, en el cuál se calculó la recta de regresión entre la velocidad del viento pronosticada y observada en cada plazo de pronóstico k , y se corrigió la muestra no considerada en esa regresión eliminando su error sistemático. Esto se repitió hasta corregir cada una de las muestras.

Más información sobre *Validación Cruzada* puede encontrarse en diversos libros sobre estadística. En particular en el presente trabajo se siguió el libro de Wilks, (2011).

3.3 Resultados

Se utilizó las siguientes alturas del modelo WRF del punto de retícula más cercano al parque eólico para ser comparadas con las observaciones del PER como se presentó en la Figura 3.2.3.3 y 3.2.3.4:

- Velocidad y dirección del viento a 10m
- Velocidad y dirección del viento a aprox. 46m
- Velocidad y dirección del viento a aprox. 92m

Respecto a la sexta configuración correspondiente al modelo GFS, las alturas consideradas fueron las siguientes:

- Velocidad y dirección del viento a 10m
- Velocidad y dirección del viento a 80m

BIAS

Previamente a la eliminación de los errores sistemáticos a través de Validación Cruzada, se procedió a calcular el BIAS para cada configuración, nivel y plazo de pronóstico. De esta forma podremos analizar si el WRF o el GFS subestiman o sobrestiman sistemáticamente la velocidad del viento, y si existen momentos del día donde las diferencias son mayores.

La Figura 3.3.1 muestra el BIAS de los pronósticos de viento para el nivel del modelo más cercano a la altura de las observaciones del PER, en función del plazo de pronóstico para las 5 configuraciones del WRF propuestas, para el GFS y para el promedio de las 5 configuraciones del WRF, correspondiente al **invierno**, mientras que la Figura 3.3.2 lo hace para el **verano**.

El viento pronosticado a 92m sobrestima a los valores observados en el PER para todos los plazos de pronóstico y todas las configuraciones del WRF tanto para el invierno como para el verano, aunque la sobrestimación es mayor en la estación invernal. Asimismo se presenta un ciclo bien definido del BIAS para el invierno, con un período de 12hs, que maximiza en los momentos de transición entre el régimen diurno y nocturno, y minimiza durante las horas diurnas. A medida que el plazo de pronóstico aumenta, la periodicidad en los errores se atenúa. En verano este ciclo se ve algo desdibujado dificultando el análisis de la variabilidad diurna del BIAS.

Para profundizar aún más el análisis, la Tabla 3.3.1 muestra el BIAS encontrado para cada configuración utilizando los pronósticos para todos los plazos entre 0 y 48 hs, para los regímenes diurnos y nocturnos, en invierno y verano, y el intervalo de confianza de 95%. Se determinaron las horas diurnas y nocturnas a aquellas que pertenecen a los intervalos [12 hs - 15 hs], y [0 hs - 3 hs], correspondientes a la hora local argentina.




Figura 3.3.1. BIAS [m/s] de la intensidad del viento en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de invierno.




Figura 3.3.2. BIAS [m/s] de la intensidad del viento en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de verano.

H_WRF = 92m y H_GFS = 80m	INVIERNO			VERANO		
	BIAS [m/s]			BIAS [m/s]		
	Config.	[0-48] hs	Diurno	Nocturno	[0-48] hs	Diurno
C1	1.76 [1.64 - 1.89]	1.75 [1.42 - 2.07]	1.52 [1.21 - 1.83]	1.15 [1.03 - 1.28]	0.95 [0.67 - 1.22]	1.71 [1.42 - 1.99]
C2	1.61 [1.48 - 1.73]	1.43 [1.13 - 1.75]	1.38 [1.02 - 1.73]	1.06 [0.94 - 1.18]	0.81 [0.54 - 1.08]	1.77 [1.49 - 2.07]
C3	1.71 [1.58 - 1.83]	1.89 [1.56 - 2.19]	1.47 [1.14 - 1.78]	1.01 [0.89 - 1.13]	0.45 [0.20 - 0.71]	1.76 [1.47 - 2.05]
C4	2.07 [1.95 - 2.20]	2.09 [1.78 - 2.38]	1.99 [1.66 - 2.32]	1.17 [1.04 - 1.31]	0.77 [0.50 - 1.04]	2.07 [1.80 - 2.36]
Ctrl	2.02 [1.90 - 2.14]	1.98 [1.69 - 2.29]	2.03 [1.75 - 2.31]	1.54 [1.41 - 1.67]	1.39 [1.12 - 1.69]	2.07[1.75 - 2.39]
GFS	0.75 [0.51 - 0.90]	1.27 [0.92 - 1.62]	0.70 [0.35 - 1.03]	1.30 [1.16 - 1.44]	0.20[-0.11 - 0.51]	2.38[2.06 - 2.70]
MEDIA WRF	1.87 [1.74 - 1.99]	1.88 [1.58 - 2.18]	1.72 [1.44 - 2.00]	1.17 [1.06 - 1.29]	0.85[0.60 - 1.10]	1.88[1.63 - 2.14]

Tabla 3.3.1. BIAS [m/s] del viento para todas las configuraciones, para los plazos de pronóstico de 0 a 48 hs, regímenes diurnos y nocturnos, correspondientes a las estaciones de invierno y verano. Los valores entre corchetes indican el intervalo de confianza del 95%.

El BIAS promedio considerando los plazos de pronóstico 0-48 hs para cada configuración del WRF es menor en verano respecto al invierno, con una significancia superior al 95%. El intervalo de confianza fue calculado a partir de la muestra de pronósticos y observaciones de intensidad de viento consideradas en este Capítulo, a la cual le fue aplicada la metodología de “*Bootstrap*” (Wilks, 2011) considerando cada uno de los pronósticos como experimentos independientes y realizando 1000 repeticiones.

Al comparar el BIAS de la intensidad del viento de las 5 configuraciones propuestas del WRF, se observa que C1, C2 y C3 producen un BIAS significativamente menor a C4 y Ctrl en invierno considerando todos los plazos de pronóstico entre 0 y 48hs. En verano en cambio la única configuración que produce errores sistemáticos mayores a las restantes es la configuración Ctrl. Esto puede deberse a que el valor de altura del terreno para el punto de retícula del WRF más cercano al PER es mayor respecto al de las configuraciones en alta resolución, produciendo valores de intensidad de viento levemente superiores.

Respecto al BIAS diurno en invierno, C2 presenta el valor más bajo mientras C4 presenta el valor más alto, siendo además significativamente mayor al BIAS de C2, con el 95% de significancia. En verano no existe ninguna configuración que produzca valores de BIAS mayores/menores a las restantes.

El menor BIAS nocturno corresponde a C2 en invierno, aunque este es significativamente menor únicamente respecto del valor asociado a la configuración Ctrl. En las horas nocturnas de la estación estival no hay configuración que produzca valores de BIAS mayores/menores al resto.

A pesar que el modelo GFS proporciona pronósticos de viento a la altura de los instrumentos (80m), sus pronósticos también sobrestiman las observaciones de viento del PER, aunque en menor grado, siendo esta diferencia más marcada en verano que en invierno. El BIAS en ambas estaciones para el GFS es significativamente menor al de cualquier configuración del WRF, con un 95% de confianza. Esto es esperable ya que en condiciones normales y para estas alturas, la velocidad del viento se incrementa con la altura. Además, en verano, el BIAS del modelo GFS es mayor en las horas nocturnas respecto de las diurnas.

RMSEdb y Coeficiente de Correlación (R): Variación temporal y direccional

Una vez identificada la presencia de errores sistemáticos en los pronósticos de intensidad de viento, se decidió eliminarlos a partir de la implementación de la técnica de Validación Cruzada mencionada en la Sección 3.2.7. De esta manera calculamos un nuevo índice de error llamado RMSEdb, utilizando los pronósticos de viento corregidos.

Las Figuras 3.3.3 y 3.3.4 presentan la evolución temporal del RSMEdb de la intensidad del viento para cada plazo de pronóstico, para el invierno y el verano respectivamente. Nuevamente se consideró la altura del modelo WRF y GFS más cercana a la altura de las observaciones de viento del PER.

Si bien se aprecia un detrimento en la calidad de los pronósticos de intensidad del viento con el plazo de pronóstico, dentro de las primeras 48 hs no parece haber incrementos sustantivos en el RMSEdb. Sin embargo se observan ciclos marcados en los cuáles predomina la ocurrencia de mínimos valores de RMSEdb cerca del mediodía local y al atardecer, en invierno (alrededor de 2 m/s), con un ciclo regular que se desdibuja en verano.




Figura 3.3.3. RMSEdb [m/s] de la intensidad del viento corregido en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de invierno.




Figura 3.3.4. RMSEdb [m/s] de la intensidad del viento corregido en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de verano.

Análogamente al análisis realizado para el BIAS, la Tabla 3.3.2 muestra el RMSEdb de la intensidad del viento para cada configuración, utilizando los pronósticos para todos los plazos entre 0 y 48 hs, para los regímenes diurnos y nocturnos, en invierno y verano, y el intervalo de confianza de 95%. Nuevamente las horas diurnas y nocturnas son aquellas que pertenecen a los intervalos [12 hs - 15 hs], y [0 hs - 3 hs], correspondientes a la hora local argentina.

El menor valor de RMSEdb para el invierno y considerando todos los plazos de pronóstico involucrados en las primeras 48 hs, corresponde a la media del ensamble de pronósticos de WRF, mientras que la configuración individual que presenta el menor valor de RMSEdb es Ctrl. Si bien no existen diferencias significativas entre las distintas configuraciones del WRF, podemos afirmar que los pronósticos de GFS producen errores sensiblemente superiores a cualquier configuración del WRF en esta estación del año.

En verano y también considerando las primeras 48 hs de pronóstico, nuevamente el valor promedio del ensamble de WRF es el que presenta los menores errores. C1 es el pronóstico determinístico que produce los menores valores de RMSEdb. Sin embargo no hay diferencias significativas al 95% que permitan determinar si alguna configuración del WRF se desempeña mejor que el resto. Complementariamente y así como sucedió en invierno, los pronósticos de GFS producen errores significativamente superiores a la media del ensamble de WRF.

H_WRF = 92m y H_GFS = 80m	INVIERNO			VERANO		
	RMSEdb [m/s]			RMSEdb [m/s]		
	[0-48] hs	Diurno	Nocturno	[0-48] hs	Diurno	Nocturno
Config.						
C1	2.66 [2.58 - 2.76]	2.79 [2.55 - 3.00]	2.75 [2.51 - 3.00]	2.56 [2.46 - 2.66]	2.37 [2.11 - 2.63]	2.26 [2.04 - 2.48]
C2	2.69 [2.59 - 2.79]	2.76 [2.54 - 2.97]	2.94 [2.68 - 3.21]	2.60 [2.50 - 2.71]	2.36 [2.09 - 2.66]	2.21 [2.02 - 2.40]
C3	2.65 [2.56 - 2.74]	2.78 [2.58 - 3.03]	2.77 [2.56 - 3.00]	2.59 [2.49 - 2.71]	2.31 [2.09 - 2.55]	2.18 [1.99 - 2.38]
C4	2.67 [2.58 - 2.75]	2.71 [2.50 - 2.94]	2.79 [2.58 - 3.01]	2.63 [2.53 - 2.72]	2.43 [2.17 - 2.69]	2.22 [2.02 - 2.41]
Ctrl	2.62 [2.54 - 2.71]	2.75 [2.53 - 2.97]	2.68 [2.45 - 2.91]	2.61 [2.51 - 2.71]	2.47 [2.19 - 2.74]	2.36 [2.15 - 2.57]
GFS	2.97 [2.86 - 3.07]	2.91 [2.70 - 3.12]	3.00 [2.74 - 3.27]	2.74 [2.65 - 2.85]	2.56 [2.32 - 2.84]	2.41 [2.18 - 2.63]
MEDIA WRF	2.59 [2.51 - 2.68]	2.70 [2.49 - 2.91]	2.69 [2.47 - 2.89]	2.50 [2.40 - 2.60]	2.32 [2.05 - 2.60]	2.14 [1.96 - 2.33]

Tabla 3.3.2. RMSEdb [m/s] del viento a para todas las configuraciones, para los plazos de pronóstico de 0 a 48 hs, regímenes diurnos y nocturnos, correspondientes a las estaciones de invierno y verano. Los valores entre corchetes indican el intervalo de confianza del 95%.

Si ahora consideramos cualquier configuración del WRF e incluso el promedio de su ensamble (MEDIA WRF), no se observan diferencias significativas entre los valores de RMSEdb en ambas estaciones del año y considerando todos los pronósticos dentro de la ventana 0-48hs. En cambio para el modelo global GFS los errores son significativamente superiores en invierno respecto al verano.

El mismo análisis hecho para las horas diurnas muestra que únicamente C3 produce errores significativamente inferiores en verano respecto al invierno para estas horas del día. Para las horas nocturnas todas las configuraciones analizadas a excepción de Ctrl presentan valores de RMSEdb inferiores en verano respecto al invierno. Esto está fuertemente relacionado con que el ciclo medio diurno de la velocidad del viento en el PER es más marcado en verano, donde los menores valores se presentan en horas nocturnas, mostrando además una menor variabilidad del viento en esas horas. Para el invierno la amplitud del ciclo medio diurno desaparece casi por completo y presenta valores altos de intensidad de viento a lo largo de todo el día.

El análisis realizado para los pronósticos de viento del nivel más cercano a las observaciones (92m y 80m para WRF y GFS respectivamente) fue también hecho para los pronósticos de viento a 10m. Luego de haber eliminado los errores sistemáticos (que en este caso y dado que se estaba comparando el viento pronosticado a 10m respecto del viento observado a 80m, el BIAS era negativo), no se observan diferencias significativas con 95% de confianza entre los valores de RMSEdb de los pronósticos a 10m o a la altura del modelo más cercana a las observaciones. Esto implica que existe poco impacto en la elección del nivel vertical que se escoja siempre y cuando los errores sistemáticos hayan sido correctamente eliminados. Este impacto, en términos medios, es menor a 2%, sugiriendo la posibilidad de utilizar el viento a 10m como predictor en la estimación de la intensidad del viento a la altura del eje de los aerogeneradores.

En el trabajo de Draxl y otros, (2014) los autores encuentran que las simulaciones realizadas para Høvsøre, en Dinamarca, considerando únicamente las salidas del modelo entre 7-30hs, poseen un RMSE entre [2.49 m/s – 2.69 m/s] para 7 parametrizaciones diferentes de CLA, y para una altura de 60m sobre el nivel del suelo. El valor mínimo de RMSE pertenece a la configuración del WRF que utiliza la parametrización de CLA de MYJ. Los valores de RMSEdb encontrados en nuestros experimentos distan poco respecto a los encontrados en el trabajo de Dinamarca, aunque debe tenerse en consideración que el RMSEdb incluye una corrección de los errores sistemáticos de los pronósticos que no ha sido realizada en el trabajo de Draxl y otros, (2014).

Las Figuras 3.3.5 y 3.3.6 presentan la evolución temporal del coeficiente de correlación R de los pronósticos corregidos de la intensidad del viento, para el invierno y el verano respectivamente. Nuevamente se consideró la altura del modelo WRF y GFS más cercana a la altura de las observaciones de viento del PER.




Figura 3.3.5. Coeficiente de correlación (R) de la intensidad del viento en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de invierno.




Figura 3.3.6. Coeficiente de correlación (R) de la intensidad del viento en función del plazo de pronóstico para las diferentes configuraciones del WRF y para GFS, correspondiente a las 45 simulaciones de verano.

La serie temporal del coeficiente de correlación muestra un deterioro mayor que el RMSEdb en función del plazo de pronóstico el cual se acentúa más en verano respecto al invierno. Si se compara el coeficiente de correlación calculado para el rango de plazos de pronóstico entre 12 y 36 hs, respecto del valor encontrado para los plazos de pronóstico entre 36 y 60 horas, se encuentra que el último valor es significativamente superior al primero, con una significancia mayor al 99%.

Asimismo pocas veces se supera el valor de 0.8 considerando todos los plazos de pronósticos y configuraciones. Asimismo existen algunos plazos de pronóstico para los cuales la correlación puede ser muy baja, con valores incluso inferiores a 0.2.

La Tabla 3.3.3 presenta los valores del coeficiente de correlación para cada configuración, utilizando los pronósticos para todos los plazos entre 0 y 48 hs, para los regímenes diurnos y nocturnos, en invierno y verano, y el intervalo de confianza de 95%.

Considerando las 48 primeras horas de pronóstico, el coeficiente de correlación del promedio del ensamble de simulaciones hechas con el WRF presenta los valores más altos tanto en invierno como en verano. En la estación invernal su valor es significativamente superior respecto de los pronósticos hechos con el modelo global GFS e incluso siendo mayor a los valores encontrados para C2. En verano solamente los pronósticos de GFS presentan valores de R significativamente inferiores a la media de los pronósticos determinísticos hechos con el modelo WRF.

Con respecto a los valores de R para las horas diurnas y nocturnas, no hay diferencias significativas entre las distintas configuraciones, aunque en términos medios la media del ensamble presenta valores superiores al resto, salvo para las horas diurnas en la estación invernal en las cuales C4 posee un valor de R levemente mayor.

Config.	INVIERNO			VERANO		
	Coeficiente de correlación			Coeficiente de correlación		
	[0-48] hs	Diurno	Nocturno	[0-48] hs	Diurno	Nocturno
C1	0.691 [0.666 - 0.717]	0.710 [0.658 - 0.763]	0.656 [0.577 - 0.734]	0.713 [0.685 - 0.740]	0.734 [0.670 - 0.798]	0.683 [0.626 - 0.738]
C2	0.649 [0.621 - 0.677]	0.706 [0.653 - 0.764]	0.531 [0.449 - 0.609]	0.702 [0.676 - 0.729]	0.737 [0.673 - 0.807]	0.700 [0.648 - 0.751]
C3	0.696 [0.670 - 0.722]	0.709 [0.656 - 0.762]	0.654 [0.580 - 0.733]	0.702 [0.674 - 0.731]	0.750 [0.696 - 0.806]	0.706 [0.648 - 0.764]
C4	0.688 [0.664 - 0.712]	0.727 [0.678 - 0.777]	0.651 [0.587 - 0.720]	0.695 [0.668 - 0.723]	0.717 [0.648 - 0.787]	0.698 [0.638 - 0.759]
Ctrl	0.699 [0.675 - 0.721]	0.714 [0.659 - 0.767]	0.677 [0.611 - 0.750]	0.700 [0.673 - 0.726]	0.707 [0.637 - 0.778]	0.647 [0.581 - 0.714]
GFS	0.597 [0.567 - 0.629]	0.678 [0.623 - 0.735]	0.578 [0.490 - 0.668]	0.658 [0.630 - 0.686]	0.677 [0.606 - 0.747]	0.623 [0.556 - 0.692]
MEDIA WRF	0.707 [0.684 - 0.730]	0.726 [0.675 - 0.775]	0.676 [0.608 - 0.752]	0.730 [0.703 - 0.756]	0.748 [0.683 - 0.816]	0.723 [0.670 - 0.776]

Tabla 3.3.3. Coeficiente de correlación para todas las configuraciones, para los plazos de pronóstico de 0 a 48 hs, regímenes diurnos y nocturnos, correspondientes a las estaciones de invierno y verano. Los valores entre corchetes indican el intervalo de confianza del 95%.

Una de las preguntas presentes es si el RMSEdb y la correlación son homogéneos direccionalmente, es decir, si tienen los mismos valores independientemente del sector donde provenga el viento. Para ver este comportamiento se calcularon los distintos índices para los 8 sectores de viento principales observados en el PER, incluyendo las primeras 48 hs de pronóstico. Es decir que en cada sector de viento se guardan aquellos pares de pronósticos y observaciones en las cuales la dirección de viento observada cae dentro del respectivo cuadrante. Esto implica que la intensidad de viento pronosticada puede no estar asociada al mismo sector de viento registrado en las observaciones. Con esta consideración, la Figura 3.3.7 muestra el RMSEdb para todas las configuraciones en función del sector de dirección para la estación invernal, y para la altura del modelo WRF y GFS más cercana a las mediciones en el PER, mientras que la Figura 3.3.8 lo hace para el verano.




Figura 3.3.7. RMSEdb [m/s] en función del sector de viento predominante para las diferentes configuraciones, en la estación invernal. Se utilizaron los pares de pronóstico y observaciones dentro del rango 0 – 48 hs.

Para ambas estaciones del año los menores valores de RMSEdb se alcanzan cuando el viento proviene de los sectores N, NE y S, mientras que los máximos ocurren con vientos del sector E, SE en invierno, y SO y O en verano. Si observamos la Tabla 3.3.4, que indica la frecuencia relativa, intensidad media del viento y desvío estándar para cada sector principal del viento, podemos apreciar que los menores errores coinciden con los menores valores de desvío estándar del viento, salvo para el sector S en invierno, mientras que los sectores O y SO presentan los valores más alto de desvío estándar en verano, y los sectores E y SE en invierno.




Figura 3.3.8. RMSEdb [m/s] en función del sector de viento predominante para las diferentes configuraciones, en la estación estival. Se utilizaron los pares de pronóstico y observaciones dentro del rango 0 – 48 hs.

	INVIERNO			VERANO		
	Frecuencia	Promedio [m/s]	SD [m/s]	Frecuencia	Promedio [m/s]	SD [m/s]
N	6.5%	6.13	2.89	10.3%	6.61	2.64
NE	1.2%	4.14	1.16	9.0%	6.34	2.48
E	2.1%	7.24	3.87	9.3%	6.9	3.32
SE	4.4%	7.41	4.69	19.7%	7.28	3.5
S	6.3%	8.23	3.78	4.7%	6.37	2.32
SO	20.4%	9.93	3.63	14.6%	10.31	4.01
O	36.4%	8.76	3.34	22.3%	9.09	3.72
NO	22.7%	7.5	3.06	7.6%	6.14	2.73

Tabla 3.3.4. Frecuencia, velocidad media y desvío estándar del viento para cada sector principal, y para las estaciones de invierno y verano a partir de las observaciones de viento del PER correspondientes a los mismos plazos de pronóstico de las distintas configuraciones, considerando solamente las primeras 48 hs.

Las Figuras 3.3.9 y 3.3.10 son idénticas a las anteriores, pero éstas corresponden ahora al coeficiente de correlación. En este caso se observa que las mayores correlaciones se dan en los sectores SE, S y N para el invierno, mientras que en verano los sectores con las correlaciones más altas corresponden al N, SE y SO. Una singularidad se observa en los valores de correlación del sector NE en invierno. En este caso vemos que a pesar de que el RMSEdb en este sector para el invierno tenía los valores más bajos, la correlación para todas las configuraciones son las mínimas, incluso alcanzando valores negativos para alguna de ellas. Esta característica incluso es observada para todas las configuraciones propuestas, presentando incluso para C1 valores de correlación negativos. Esto puede deberse a que en principio hay muy pocos casos de vientos provenientes de ese sector en invierno (en esta muestra sólo 1.2% del tiempo el viento proviene de esa dirección), y los modelos son incapaces de representar correctamente la circulación asociada que tiene el flujo de aire

cuando el viento proviene del NE. Veremos más adelante en esta misma sección que los errores en la dirección del viento maximizan en invierno cuando el viento observado es del NE superando en un 500% los errores encontrados, por ejemplo, en la dirección del viento cuando el mismo proviene del sector oeste.

Otra de las características presentes en estas figuras es la poca variación del coeficiente de correlación entre configuraciones para cada dirección del viento, mostrando el poco impacto que tiene direccionalmente la elección de la parametrización de capa límite y la resolución horizontal.




Figura 3.3.9. Coeficiente de correlación en función del sector de viento predominante para las diferentes configuraciones para el invierno.




Figura 3.3.10. Coeficiente de correlación en función del sector de viento predominante para las diferentes configuraciones para el verano.

Variación del RMSEdb y coeficiente de correlación (R) para distintas clases de estabilidad:

La longitud de Monin-Obukhov es un parámetro escalar utilizado en la Teoría de Similitud para la capa superficial. Su completa deducción así como su interpretación física puede seguirse en Stull, (1988) pág. 183-185. Este parámetro se define como:

$$L = \frac{-\overline{\theta_v} u_*^3}{kg(\overline{w'\theta_v'})_s} \quad \text{Ec. 3.3.1}$$

Donde u_* es la velocidad de fricción, $\overline{\theta_v}$ es la temperatura potencial virtual del flujo medio, $(\overline{w'\theta_v'})_s$ es el flujo vertical turbulento de temperatura potencial virtual dentro de la capa superficial, k es la constante de von-Kàrmán, y g la aceleración de la gravedad.

La interpretación física de L está dada en la Teoría de Similitud de Monin-Obukhov. Durante el día, $|L|$ es la altura a la cual la producción térmica de energía cinética turbulenta es igual a la producida mecánicamente por la cortante del viento.

El signo de L determina la estabilidad en el lugar de estudio. Valores negativos están relacionados con entornos inestables, mientras que valores positivos están asociados a condiciones estables.

Siguiendo el trabajo de Draxl y otros, (2014), se proponen las siguientes clases de estabilidad en función de la longitud de Monin-Obukhov.

Clase de estabilidad	L [m]
Inestable	$-500 \leq L < -50$
Neutral	$ L > 500$
Casi Estable	$200 < L \leq 500$
Estable	$50 < L \leq 200$
Muy Estable	$10 < L \leq 50$

Tabla 3.3.5. Caracterización de la estabilidad en función de la longitud de Monin-Obukhov.

Debido a la ausencia de estimaciones medidas de L en el PER, utilizamos los valores estimados por el modelo WRF en cada una de las 5 configuraciones que involucran este modelo. Si bien este primer acercamiento puede no reflejar la situación real de la estabilidad estática, entendiendo estas limitaciones, podemos analizar la variabilidad del RMSEdb para cada una de las clases propuestas, tomando como referencia el valor de L tal como lo representa cada configuración.

La Tabla 3.3.6 muestra la frecuencia relativa de cada clase de estabilidad para invierno y verano. Para este análisis las configuraciones C1 a C4 incluyen las 72hs de pronóstico, mientras que la configuración Ctrl solo 48 hs.

	INVIERNO					VERANO				
	I	N	CE	E	ME	I	N	CE	E	ME
C1	18.1%	12.6%	11.4%	31.7%	26.2%	42.1%	13.2%	10.2%	18.8%	15.6%
C2	16.6%	15.9%	16.1%	31.9%	19.6%	45.3%	19.6%	10.3%	13.4%	11.5%
C3	14.9%	18.7%	16.9%	32.0%	17.5%	41.6%	18.0%	11.3%	16.7%	12.4%
C4	15.7%	19.6%	14.8%	31.4%	18.6%	44.6%	17.9%	9.6%	15.7%	12.3%
Ctrl	18.2%	16.5%	15.3%	32.6%	17.4%	43.0%	15.6%	12.4%	18.1%	10.9%

Tabla 3.3.6. Frecuencia relativa para cada clase de estabilidad. I: Inestable, N: Neutral, CE: Casi Estable, E: Estable y ME: Muy estable.

En el invierno predominan las condiciones estáticamente estables, con mayor frecuencia relativa para la configuración Ctrl, mientras que en el verano existe un claro predominio de condiciones estáticamente inestables, con mayor frecuencia de horas para la configuración C2. Cabe destacar que no necesariamente debe existir una coincidencia entre configuraciones ya que justamente estamos trabajando con las clases de estabilidad determinadas por cada configuración del modelo.

Las Tablas 3.3.7 y 3.3.8 muestran la velocidad media y el desvío estándar medidos en el PER para cada configuración y clase de estabilidad.

	INVIERNO					VERANO				
	I	N	CE	E	ME	I	N	CE	E	ME
C1	8.65	10.8	10.8	9.2	7.3	9.6	9.1	9.5	7.9	6.4
C2	7.68	10.2	10.2	8.2	6.3	9.1	9.5	8.6	7.3	5.7
C3	7.67	10.7	10.2	8.5	6.2	9.2	9.5	8.8	7.1	5.6
C4	7.64	10.4	10.2	8.6	6.9	9.1	9.6	9.1	7.5	5.9
Ctrl	8.05	10.6	10.7	8.5	6.5	9.4	9.3	9.1	7.5	5.6

Tabla 3.3.7. Velocidad media [m/s] medida en el PER para cada configuración y clase de estabilidad. I: Inestable, N: Neutral, CE: Casi Estable, E: Estable y ME: Muy estable.

	INVIERNO					VERANO				
	I	N	CE	E	ME	I	N	CE	E	ME
C1	3.7	4.2	3.3	3.1	2.7	4.2	4.60	4.0	2.9	2.5
C2	3.3	4.1	3.0	2.9	2.4	3.7	4.4	3.2	2.6	2.0
C3	3.3	4.2	3.0	3.0	2.4	3.7	4.5	3.3	2.6	2.0
C4	3.3	4.1	3.2	3.0	2.6	3.7	4.6	3.4	2.7	2.2
Ctrl	3.4	4.3	3.4	2.9	2.4	3.9	4.7	4.0	2.5	2.3

Tabla 3.3.8. Desvío estándar [m/s] del PER para cada configuración y clase de estabilidad. I: Inestable, N: Neutral, CE: Casi Estable, E: Estable y ME: Muy estable.

Los vientos más intensos están asociados a condiciones de estabilidad Neutra y Casi Estable en invierno, e Inestable y Neutra en verano. Además si se analiza el caso particular de las 3 condiciones de estabilidad, la velocidad media disminuye cuanto más estable se encuentra la capa superficial de la atmósfera, y lo mismo sucede con el desvío estándar del viento.

La Figura 3.3.11 muestra el RMSEdb en función de la clase de estabilidad para cada configuración del WRF para el invierno, mientras que la Figura 3.3.12 lo hace para el verano.

En general se cumple que los menores valores de RMSEdb ocurren en condiciones muy estables, tanto en invierno como en verano para todas las configuraciones, salvo para la configuración C4 y Ctrl en invierno, donde el error es mínimo bajo condiciones de inestabilidad. Complementariamente en condiciones neutras y casi estables es donde ocurren los mayores errores en invierno, coincidentes con las velocidades medias más elevadas y mayores desvíos estándar observados en el PER. Lo mismo ocurre en verano, superando incluso valores de RMSEdb de 3 m/s. Sin embargo mediante este análisis no podemos aislar la condición de estabilidad estática como causante de los mayores/menores errores debido a que en conjunto con esta característica tenemos valores mayores/menores de viento y de desvío estándar que, como se mencionó anteriormente, están relacionados con la calidad de los pronósticos de intensidad de viento.

La Figura 3.3.13 muestra el coeficiente de correlación en función de la clase de estabilidad para cada configuración del WRF para el invierno y la Figura 3.3.14 lo hace para el verano. En estas figuras puede observarse que la correlación es máxima bajo condiciones inestables y neutras, y descende abruptamente a medida que aumenta la estabilidad. La formulación de la parametrización de CLA permitiría representar mejor el flujo en capas bajas en estos dos tipos de condiciones de estabilidad estática, dificultándose la representación de la variabilidad temporal del viento bajo condiciones de estabilidad.




Figura 3.3.11. RMSEdb [m/s] para cada clase de estabilidad y todas las configuraciones del WRF, para el invierno.




Figura 3.3.12. RMSEdb [m/s] para cada clase de estabilidad y todas las configuraciones del WRF, para el verano.




Figura 3.3.13. Coeficiente de correlación para cada clase de estabilidad y todas las configuraciones del WRF, para el invierno.




Figura 3.3.14. Coeficiente de correlación para cada clase de estabilidad y todas las configuraciones del WRF, para el verano.

Si bien la comparación entre las distintas configuraciones muestra un comportamiento similar, el coeficiente de correlación en los tres rangos de estabilidad propuestos es levemente superior en las configuraciones C1 y Ctrl, las cuales poseen la parametrización de capa límite atmosférica de YSU. Vale destacar que sólo corresponde a las muestras consideradas sin ningún análisis de significancia.

RMSEdb de la dirección del viento

Luego de haber corregido los errores sistemáticos de las componentes u y v del viento a través de validación cruzada para cada una de estas componentes y calculando la dirección del viento en grados sexagesimales, se procedió a calcular el RMSEdb para la dirección del viento utilizando la definición del error en la dirección, propuesta en la Ec. 3.2.7.5. La serie temporal del RMSEdb para el invierno y verano puede observarse en la Figura 3.3.15 para el invierno, y 3.3.16 para el verano.

Los valores de RMSEdb son menores en invierno que en verano. Como vimos en el Capítulo 2 y en la Tabla 3.3.4 del presente capítulo, en invierno aumenta considerablemente el flujo del oeste respecto de lo que sucede en verano, y el modelo WRF es capaz de representar este movimiento dominante de mayor escala con menor error. En verano en cambio la rosa de los vientos muestra una mayor distribución direccional del viento, en el cual las circulaciones de menor escala cumplen un rol importante en los alrededores del PER debido a la cercanía existente entre éste y la línea de costa.

Este comportamiento se repite para todas las configuraciones propuestas, con leves diferencias entre éstas.




Figura 3.3.15. RMSEdb (en grados sexagesimal) de la dirección del viento en función del plazo de pronóstico, de las diferentes configuraciones para el invierno.




Figura 3.3.16. RMSEdb (en grados sexagesimal) de la dirección del viento en función del plazo de pronóstico, de las diferentes configuraciones para el verano.

Si analizamos la variación direccional del RMSEdb para la dirección del viento (Figuras 3.3.17 y 3.3.18), se observa la dificultad en la representación de la dirección del viento en todo el sector Este (desde el NE al SE), que posee poca frecuencia de ocurrencia (Tabla 3.3.4), para el invierno. Sin embargo, el RMSEdb de la dirección del viento de los sectores S a NO (85% de ocurrencia), muestra valores inferiores a 40° para todas las configuraciones.

En verano el RMSEdb de la dirección del viento se hace más homogéneo direccionalmente, aunque siguen siendo mejor representadas las direcciones del viento cuando el flujo de aire

proviene de los sectores SO y O, encontrándose como en invierno, con valores por debajo de 40°.

Tanto en invierno como en verano, hay poca variación en el RMSEdb de la dirección del viento entre las distintas configuraciones propuestas, no hallándose alguna que se desempeñe mejor en todos los casos.




Figura 3.3.17. RMSEdb (en grados sexagesimales) en función del sector de viento predominante para las diferentes configuraciones, en el invierno.




Figura 3.3.18. RMSEdb (en grados sexagesimales) en función del sector de viento predominante para las diferentes configuraciones, en el verano.

3.4 Discusión y conclusiones del capítulo

En el presente capítulo se analizó el desempeño de 5 configuraciones distintas del modelo WRF y el pronóstico determinístico de GFS en la representación de la intensidad y dirección del viento, comparando estos pronósticos con las mediciones de viento del Parque Eólico Rawson emplazado en la región Noreste patagónica.

Las primeras cuatro configuraciones del WRF diferían en la elección de la parametrización de capa límite atmosférica y capa superficial, esta última ligada a la elección de la primera, mientras que la quinta configuración presentaba un dominio levemente diferente, y un distanciamiento entre puntos de retícula mayor, aunque mantenía las mismas parametrizaciones elegidas para la primer configuración. Debido a que el objetivo estaba relacionado con la representación del viento en capas bajas, se propuso una densidad alta de niveles verticales cerca de la superficie en todos los experimentos. En particular todas las configuraciones del WRF presentaban 5 niveles por debajo de los 100m, y 50 niveles verticales en total.

Se comparó el viento pronosticado en el nivel del WRF y GFS más cercano a la altura de las mediciones de viento en el PER (aprox. 92m para WRF, y 80m para GFS), y se analizaron los errores sistemáticos y no sistemáticos de los pronósticos. Los resultados fueron basados en 45 simulaciones inicializadas a las 12 UTC para el invierno y 45 para el verano.

Respecto a los errores sistemáticos, los pronósticos de intensidad de viento en esos niveles sobrestimaban la velocidad medida en el PER siendo estos errores mayores en invierno que en verano. Además se observa que en verano el BIAS es significativamente menor en horas diurnas respecto de las nocturnas.

Luego de haber extraído los errores sistemáticos realizando una regresión lineal entre los valores pronosticados y observados en conjunto con la aplicación de Validación Cruzada debido al pequeño tamaño de las muestras experimentales, se procedió a analizar los errores no sistemáticos y la correlación de las series de viento corregidas con los datos observados. El error cuadrático medio de los pronósticos de viento corregidos a través de esta metodología lo hemos denominado RMSEdb.

Respecto a los errores no sistemáticos, el RMSEdb de la intensidad del viento no presenta diferencias significativas entre ambas estaciones del año y considerando todos los pronósticos dentro de la ventana 0-48hs. En cambio para el modelo global GFS los errores son significativamente superiores en invierno respecto al verano.

Si se analiza el RMSEdb promedio de las primeras 48hs de pronóstico en función de las alturas del modelo, este índice de error varía alrededor de un 2%, mostrando el poco impacto que tiene la elección de la altura del modelo en el pronóstico del viento cuando los errores sistemáticos son eliminados apropiadamente, siendo estas diferencias no significativas con una confianza del 95%.

Respecto al valor del RMSEdb en los regímenes diurnos y nocturnos, no hay diferencias significativas entre éstos dentro de la misma estación del año, aunque si existen diferencias significativas entre los valores diurnos de RMSEdb entre ambas estaciones, para la

configuración C3. Asimismo los valores de RMSEdb nocturnos entre ambas estaciones son superiores en invierno para el GFS y todas las configuraciones del WRF, a excepción de la configuración denominada Ctrl.

Los valores de RMSEdb son alrededor de un 13% mayor para la configuración GFS, siendo además significativamente mayor al 95% exponiendo la ventaja de realizar simulaciones regionales con el modelo WRF. De forma opuesta, y a pesar de que solo se consideraron 5 configuraciones, la utilización del viento promedio de este pequeño ensamble de 5 miembros reduce los valores de RMSEdb en todos los casos, aunque esta disminución no es significativa. Dado que no existen diferencias notorias entre los valores de RMSEdb de las configuraciones de alta resolución (C1 a C4) respecto de la de baja resolución (Ctrl), y teniendo en cuenta que el valor promedio del ensamble obtuvo mejores resultados, es posible que existiendo una capacidad computacional limitada, el esfuerzo debería estar orientado a la realización de un ensamble de simulaciones en menor resolución para obtener mejores resultados, incluso con otros beneficios asociados a esta práctica.

El análisis direccional del RMSEdb para la intensidad del viento muestra una fuerte variabilidad según la dirección predominante del viento. Cuando el viento proviene de aquellos sectores con mayor varianza observada, mayores son los valores de RMSEdb, y viceversa.

Se estudió también la variación del RMSEdb en función de las condiciones de estabilidad de la atmósfera. Debido a que no se contaba con información medida de variables que ayuden a determinar la estabilidad atmosférica, se infirió ésta a través de la longitud de Monin-Obukhov estimada por las distintas configuraciones del WRF. En general se cumple que los menores valores de RMSEdb ocurren en condiciones muy estables, tanto en invierno como en verano para todas las configuraciones. Bajo condiciones neutras y casi estables es donde ocurren los mayores errores en invierno, coincidentes con las velocidades medias más elevadas y mayores desvíos estándar observados en el PER. Lo mismo ocurre en verano, superando incluso valores de RMSEdb de 3 m/s.

En promedio para las primeras 48 hs de pronóstico, y considerando todas las alturas y configuraciones, el coeficiente de correlación nunca supera el valor de 0.7, siendo entonces la varianza del viento explicado por los modelos WRF y GFS menor al 50% de la varianza observada del viento en el PER. Sin embargo para algunos plazos de pronóstico, este coeficiente supera el valor de 0.8, y es mayor durante el régimen diurno respecto del nocturno. Además adquiere su máxima expresión en condiciones inestables y neutras para ambas estaciones del año y configuraciones del WRF.

Por último se estudiaron los errores en los pronósticos de dirección del viento. El RMSEdb de esta variable es menor en invierno respecto al verano, con valores promedios para las primeras 48 hs de pronóstico de 38° y 51° respectivamente. Asimismo existe poca dispersión entre las distintas configuraciones y modelos, siendo capaces de representar con mejor precisión el movimiento de mayor escala (sinóptica), obteniendo valores de RMSEdb para los sectores S, SO, O, y NO menores a 40°.

Dado que los modelos de pronóstico de potencia eléctrica que serán formulados en el próximo capítulo dependerán fuertemente de los pronósticos numéricos de viento, los resultados

encontrados en este capítulo comienzan a responder algunas inquietudes respecto de la elección de la resolución horizontal del modelo, selección de parametrizaciones de CLA y capa superficial, nivel del modelo más conveniente para representar el viento en el PER, beneficio de utilizar modelos numéricos regionales, entre otras cuestiones. Además permite conocer el rango de errores esperados en la predicción de la intensidad y dirección del viento.

Referencias del Capítulo 3:

- Carvalho, D., Rocha, A., Gómez-Gesteira, M., y Silva Santos, C. Sensitivity of the WRF model wind simulation and wind energy production estimates to planetary boundary layer parameterizations for onshore and offshore areas in the Iberian Peninsula. *Applied Energy*. 2014. Volume 135, pp. 234-246.
- Chen, F., y Dudhia, J. Coupling an Advanced Land-Surface/Hydrology Model with the Penn State–NCAR MM5 Modeling System. Part I: Model Description and Implementation. *Mon. Wea. Rev.* 2001. Volume 129, 569–585.
- Cohen, A. E., Cavallo, S. M., Coniglio, M. C., y Brooks, H. E. A Review of Planetary Boundary Layer Parameterization Schemes and Their Sensitivity in Simulating Southeastern U.S Cold Season Severe Weather Environments. *Weather and Forecasting*. 2015. Volume 30, pp. 591-612.
- Cutler, N., H. R. Outhred, I. F. MacGill, M. J. Kay, J. D. Kepert. Characterizing future large, rapid changes in aggregated wind power using Numerical Weather Prediction spatial fields. *Wind Energy*. 2009. Volume 12, Issue 6, pp. 542-555.
- Dierer, S., de Paus, T., Durante, F., Gregow, E., Lange, B., Lavagnini, A., Strack, M., and Tammelin, B. Predicting Wind Speed for Wind Energy; Progress of the WINDENG Project. *Wind Engineering* 2005. Volume 29(5), pp. 393-408.
- Draxl, C., Hahmann, A.N., Peña, A., y Giebel, G. Evaluating winds and vertical wind shear from Weather Research and Forecasting model forecasts using seven planetary boundary layer schemes. *Wind Energy*. 2014. Volume 17, issue 1, pp. 39-55.
- Dudhia, J. Numerical Study of Convection Observed During the Winter Monsoon Experiment Using a Mesoscale Two Dimensional Model. *J. Atmos. Sci.* 1989. Volume 46, 3077–3107.
- Giebel, G, Brownsword, R, Kariniotakis, G, Denhard, M, Draxl, C, The State-Of-The-Art in Short-Term Prediction of Wind Power. *ANEMOS.plus*. 2011.
- Hahmann, A. N., Lennard, C., Badger, J., Vincent, C. L., Kelly, M. C., Volker, P. J. H., Refslund, J. Mesoscale modeling for the Wind Atlas of South Africa (WASA) project. *DTU Wind Energy*. (DTU Wind Energy E. 2015. No. 0050 (updated)) .
- Hong, S., y Lim, J.J. The WRF Single-Moment 6-Class Microphysics Scheme (WSM6). *Journal of The Korean Meteorological Society*. 2006. Volume 42, pp. 129-151.
- Hong, S.-Y., y Pan, H.-L.: Nonlocal Boundary Layer Vertical Diffusion in a Medium-Range Forecast Model. *Mon. Wea. Rev.* 1996. Volume 124, 2322–2339.
- Janjic, Z. I. The Step-Mountain Eta Coordinate Model: Further Developments of the Convection, Viscous Sublayer, and Turbulence Closure Schemes. *Mon. Wea. Rev.* 1994. Volume 122, 927–945.
- Kain, J. S. The Kain–Fritsch Convective Parameterization: An Update. *J. Appl. Meteor.* 2004. Volume 43, 170–181.

- Madsen, H., Pinson, P., Kariontakakis, G., Nielsen, H., Nielsen, T. Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models, *Wind Engineering*. 2005. Volume 29, pp 475-489.
- Matsudo, C., y otros. High resolution model intercomparison for Convective Events during CHUVA Santa María. *Chuva International Workshop*, Sao Pablo, Brasil, Mayo 2013.
- Mlawer, E. J., Taubman, S. J., Brown P. D., Iacono M. J., y Clough, S. A. Radiative Transfer for Inhomogeneous Atmosphere: RRTM, a Validated Correlated-k Model for the Long Wave. *J. Geophys. Res.* 1997. Volume 102 (D14), 16 663–16 682.
- MMI Engineering and Atmospheric and Environmental Research, Inc. Prediction of Wind Energy Resources on the Outer Continental Shelf with Weather Models. Bureau of Ocean Energy Management (BOEM), 2012.
- Mortensen, N. G. 46200 Planning and Development of Wind Farms: Wind resource assessment using the WAsP software. *DTU Wind Energy*. (DTU Wind Energy E; No. 70(ed.2)). 2015.
- Nakanishi, M., y Niino, H. An improved Mellor–Yamada Level-3 Model With Condensation Physics: Its Design and Verification. *Bound.-Layer Meteor.* 2004. Volume 112, 1–31.
- Pinson, P., Hagedorn, R, Verification of the ECMWF ensemble forecasts of wind speed against analyses and observations, *Meteorological Applications*. 2011. Volume 00, pp 1-20.
- Reid S., Turner, R. Correlation of Real and Model Wind Speeds in Different Terrains. *Weather and Forecasting*, 2001.
- Rife, D.L., and C.A. Davis. Verification of Temporal Variations in Mesoscale Numerical Wind Forecasts. *Monthly Weather Review* 133(11), pp. 3368-3381, 2005.
- Ruiz, J.J, Saulo, C.A y Nogues-Paegle, J. WRF Model Sensitivity to choice of parameterization over South America: Evaluation Against Surface Observations. *Monthly Weather Review*. 2010. Volume 138 n°8. P3342 – 3355.
- Skamarock, W.C., y otros. A Description of the Advanced Research WRF Version 3. *NCAR Technical Notes*, NCAR/TN-4751STR. 2008.
- Sood, A., K. Suselj, and D. Heinemann. High Resolution NWP North Sea Wind Forecasts in the Marine Atmospheric Boundary Layer. *Proceedings of the European Wind Energy Conference*, Athens (GR), 2006.
- Stensrud, D.J. Parameterization Schemes: Keys to Understanding Numerical Weather Prediction Models. *Cambridge*. 2007.
- Storm, B. Dudhia, J. Basu, S. Swift, A. Giammanco, I. Evaluation of the Weather Research and Forecasting Model on Forecasting Low-level Jets: Implications for Wind Energy. *Wind Energy*-2009. Volume 12:81–90,.
- Stull, R.B. An Introduction to Boundary Layer Meteorology. *Kluwer*. 1988.

- Sukoriansky, S., Galperin, B.yPerov, V. Application of a New Spectral Theory of Stably Stratified Turbulence to the Atmospheric Boundary Layer Over Sea Ice. Bound.-Layer Meteor. 2005. Volume 117, 231–257.
- Wilks, D., S. Statistical Methods in the Atmospheric Science. Elsevier. 2011.

Capítulo 4

Formulación y validación de metodologías de pronóstico de potencia a corto y mediano plazo para el PER

En el presente capítulo se proponen y validan métodos de pronósticos horarios de potencia eléctrica a corto plazo (hasta 48 hs) para el Parque Eólico Rawson. La formulación de los pronósticos para plazos menores a 6 horas depende principalmente de la implementación de metodologías de análisis de series temporales debido a la naturaleza persistente del viento, y en particular se propondrán distintos modelos autorregresivos evaluando sus desempeños con respecto al de un modelo simplificado de referencia.

Complementariamente y debido a la ausencia de un conjunto grande de estaciones de medición de viento en la región noreste patagónica, se decidió realizar una simulación idealizada del viento en capas bajas con el modelo WRF para esta región. En este contexto cada punto de retícula del dominio simulado fue considerado como una estación meteorológica, considerando la serie temporal del punto de retícula más cercano al PER como su serie “observada”. El objetivo principal de esta sección corresponde a la formulación de métodos de pronóstico espacio-temporales bajo distintos regímenes de viento, que utilizan no sólo la autocorrelación propia de la serie temporal correspondiente al punto más cercano al PER, sino también utilizan la correlación-cruzada entre las series temporales de este punto y los restantes puntos de retícula del dominio, con distintos desfases temporales. De esta manera es posible identificar la ubicación geográfica y el aporte de aquellos predictores que influyen en mejorar la calidad de los pronósticos de intensidad de viento para el punto de retícula más cercano al PER, para distintos plazos de pronóstico y bajo distintos regímenes de viento.

Los métodos de pronóstico de potencia eléctrica a mediano plazo hacen uso de los beneficios de la historia del PER en conjunto con la utilización de MNPT para minimizar los errores del pronóstico de potencia para plazos mayores a 3 hs. Dentro de este contexto se decidió utilizar los pronósticos de viento del WRF y GFS en la formulación de los modelos de pronósticos de potencia eléctrica a mediano plazo habiendo analizado sus desempeños en el Capítulo 3.

Se considera que los errores aquí encontrados serán representativos de lo esperado en un contexto operativo de estos modelos para esta región de estudio.

4.1 Introducción general del capítulo

Los pronósticos de potencia eólica se han convertido en una herramienta muy importante para la gestión óptima de los recursos energéticos. Estos pronósticos abarcan distintos plazos de pronóstico, siendo muy común encontrar en la literatura la definición de “*pronósticos a corto plazo*” a aquellos pronósticos de potencia eléctrica (o viento transformado luego a potencia), para plazos máximos del orden de días con resoluciones temporales o pasos de tiempo de minutos a horas, como lo definen los trabajos de Costa y otros, (2008), Snodin y otros, (2006) y la completa revisión bibliográfica sobre pronósticos de potencia eléctrica realizada por Giebel y otros, (2011). Asimismo estos pronósticos pueden ser realizados para aerogeneradores individuales, parques eólicos individuales, o conglomerados de parques eólicos.

Por otro lado, se clasifican como “*pronósticos a muy corto plazo*” a aquellos que poseen pasos de tiempo de milisegundos a segundos, y plazos de pronóstico de minutos.

La utilización de los pronósticos de potencia presenta distintos propósitos según los plazos de pronóstico involucrados:

- Los pronósticos a muy corto plazo son utilizados por los operadores del parque eólico, orientados al sistema de control de los aerogeneradores.
- Los pronósticos del orden de horas a días son útiles para diferentes aplicaciones:
 - Asignación de reservas de otras fuentes de energía, en función de la previsión de energía eólica.
 - Planeamiento y optimización del despacho de energía considerando las fuentes convencionales y no convencionales. Típicamente los plazos de pronóstico cubren más de 24 hs para incluir las tareas de programación diaria de generación y despacho.
 - Optimización del valor de la energía dentro del mercado eléctrico dependiendo del sistema de tarifas adoptado por cada país/región. Típicamente los plazos de pronóstico para estos fines van de las 0 hs a las 48 hs.
 - Plazos mayores, del orden de días, están fuertemente ligados a tareas de mantenimiento de parques, líneas de transmisión, etc.

De forma general, los pronósticos de potencia comprendidos entre plazos de 1 hora a 2/3 días son los que mayor impacto económico producen a través de los siguientes beneficios:

- Ganancias económicas debido a mejores transacciones dentro del mercado eléctrico.
- Ahorros económicos debido a un mejor planeamiento de las tareas de operación y mantenimiento (programadas para aquellos momentos de baja intensidad de viento).
- Ahorros económicos debido a un mejor planeamiento del mercado eléctrico y su despacho por los operadores del sistema eléctrico. Si se prevén condiciones de gran generación de energía eólica dentro de una región, es conveniente utilizar este tipo de recurso priorizando éstos por encima de plantas de energía convencionales.

Debido a su importancia económica, la mayor parte de los métodos de investigación propuestos se concentran en estos plazos de pronóstico.

Vale mencionar que en el presente capítulo adoptaremos la definición considerada en el trabajo de Pinson, (2006) y Lei y Otros, (2009), basada en la distinción propuesta por Chatfield, (2000) entre “*modelo*” y “*método*” de pronóstico. Un *modelo* de pronóstico sólo describe la evolución temporal de las series analizadas, mientras que un *método o metodología* abarca todo el procedimiento para producir predicciones de la variable de interés. Esto se debe a que un *método* de pronóstico puede involucrar más de un *modelo* en su formulación y permite predecir el comportamiento futuro de la serie temporal de datos explicado por el modelo selecto.

Dependiendo del propósito planteado y por ende el plazo de pronóstico involucrado en conjunto con su resolución temporal, son propuestas distintas metodologías de pronóstico. En el presente capítulo no se estudiarán metodologías de pronóstico relacionadas con el control de los aerogeneradores (pronósticos a muy corto plazo); por el contrario se propondrán y evaluarán distintos métodos de pronóstico para cubrir la mayoría de las necesidades planteadas en la industria eólica, es decir, para plazos de pronóstico del orden de horas y días.

Existe una primera división de métodos de pronósticos a corto plazo de potencia eléctrica:

- Métodos estadísticos: Los métodos de pronóstico estadísticos suelen estar conformados por distintos modelos estadísticos capaces de describir el comportamiento pasado de las series temporales de viento o potencia (o cualquier variable de interés), formulados en un *período de entrenamiento* y evaluados en el *período de validación*. Los modelos utilizados no resuelven ecuaciones que describen procesos físicos, aunque si son tenidos en cuenta al proponer modelos adecuados que expliquen ciertos comportamientos físicos (ciclos diurnos, estacionales, tendencias, etc). Típicamente este tipo de métodos hacen uso de modelos de series temporales del sitio de interés, a veces involucrando las observaciones de otras estaciones/parques eólicos aledaños, y poseen un muy buen desempeño para plazos de pronóstico menores a 3-6 hs.
- Métodos físicos: Los métodos físicos incluyen en su formulación a los pronósticos generados a partir de MNPT, que abarcan la región de interés. Como vimos en el Capítulo 3, estos modelos generan campos de distintas variables meteorológicas entre las cuales se incluyen aquellas de interés para la industria eólica (dirección e intensidad de viento, temperatura, presión y humedad relativa) a distintas alturas y para distintos horizontes de pronóstico. Estos modelos suelen corregirse para adaptarse al área de estudio, reduciendo los errores sistemáticos, y luego son convertidos a potencia a través de la proposición de alguna curva de transferencia de viento a potencia eléctrica. En algunos casos los métodos físicos proponen un refinamiento de los pronósticos corregidos generados por los MNPT, introduciendo variaciones locales del flujo alrededor del parque eólico debido a cambios en la topografía y uso de suelo, presencia de obstáculos e interrelación entre aerogeneradores. La utilización de MNPT mejora sustancialmente los pronósticos de viento y potencia eléctrica para plazos mayores a 3-6 hs, siendo hoy en día utilizados en la mayoría de los sistemas de pronóstico propuestos comercialmente.

La Tabla 4.1.1 resume las diferentes aplicaciones de los pronósticos de potencia eólica y el abordaje metodológico recomendado, dependiendo del plazo de pronóstico.

Luego de estas definiciones y consideraciones, este capítulo se divide de la siguiente forma: La *Sección 4.2* plantea la formulación y evaluación de pronósticos hasta 12 hs basados en métodos estadísticos, en particular mediante la implementación de modelos autorregresivos utilizando la información horaria del PER. La *Sección 4.3* analiza la mejora en el desempeño de pronósticos de viento a corto plazo (hasta 6 hs) utilizando no sólo información localizada en las coordenadas del PER, sino también haciendo uso de las observaciones corriente arriba del sitio. Este ejercicio fue realizado dentro de un contexto teórico debido a la escasez de mediciones en la región nordeste Patagónica. Finalmente la *Sección 4.4* describe y evalúa la formulación de un método combinado entre modelos estadísticos y físicos para la realización de pronósticos de potencia eléctrica con plazo máximo de 48 hs.

Denominación	Plazo de pronóstico	Utilidad	Método de pronóstico
Pronósticos a muy corto plazo	Minutos	- Utilizados por los operadores del parque eólico, orientados al sistema de control de los aerogeneradores.	Estadístico
Pronósticos a corto plazo	Horas	- Decisiones de mercado - Planeamiento de tareas de operación y mantenimiento (Actores: operadores del parque eólico) - Planeamiento y optimización del despacho de energía considerando las fuentes convencionales y no convencionales (Actores: operadores del sistema eléctrico)	Estadístico (plazos menores a 6 horas) Estadístico + Físico (combinado) para plazos mayores a 6 horas
Pronósticos a corto plazo	Días	- Decisiones de mercado - Planeamiento de tareas de operación y mantenimiento (Actores: operadores del parque eólico) - Programación óptima de los recursos energéticos (Actores: operadores del sistema eléctrico)	Estadístico + Físico

Tabla 4.1.1. Resumen de las distintas utilidades de los pronósticos de potencia para distintos plazos de pronóstico y los métodos típicamente utilizados.

4.2 Pronósticos a corto plazo – Método basado en modelos autorregresivos

4.2.1 Introducción y antecedentes

Habiendo introducido la problemática y los métodos de pronóstico de potencia eléctrica en la Sección 4.1, tanto la presente sección como la siguiente se focalizarán en los pronósticos a corto plazo, hasta 12 hs, utilizando métodos estadísticos.

Existe una vasta cantidad de antecedentes referidos al pronóstico de viento y/o potencia eléctrica a través de distintos métodos estadísticos que utilizan modelos de series temporales. Unos de los primeros trabajos relacionados con esta temática es el correspondiente a Brown y otros, (1984), donde detalla la aplicación de modelos autorregresivos (AR) basados en el trabajo de Box y Jenkins, (1976), para el pronóstico a corto plazo de viento y potencia eléctrica a través de la implementación de una curva de transferencia. Otros trabajos que implementan modelos autorregresivos proponen y analizan el desempeño de modelos *autorregresivos de medias móviles* (ARMA, por su nombre en inglés), como el trabajo de Milligan y otros, (2004), que propone y evalúa el desempeño de distintos modelos ARMA para plazos de pronósticos máximos de 6 horas utilizando información de viento en diferentes lugares de Estados Unidos. El trabajo de Huang y Chalabi, (1995) implementa modelos autorregresivos con tendencia para el pronóstico a corto plazo de la velocidad del viento con resultados optimistas en cuanto a la aplicación de esta metodología en un entorno operativo. Sfetsos, (2002) analiza el desempeño de pronósticos horarios utilizando modelos ARMA y Redes Neuronales comparando las mejoras en el desempeño cuando se trabaja con datos diezminutales respecto a la utilización de datos horarios. Siguiendo esta misma línea el trabajo de Torres y otros, (2005) aplica la metodología propuesta por Brown y otros, (1984), pero proponiendo modelos ARMA documentando los beneficios esperados analizando los datos de viento de 5 estaciones automáticas a 10m de altura en la región de Navarra, España. Kavasseri y Seetharaman, (2009) encontraron resultados promisorios al proponer una variedad de modelos autorregresivos integrados de medias móviles (ARIMA), denominados “fractional ARIMA” (f-ARIMA) para el pronóstico horario del viento, encontrando altos valores de mejora respecto a la persistencia. Cadenas y Rivera, (2010) propusieron un modelo híbrido entre modelos ARMA y Redes Neuronales Artificiales, o ANN por sus siglas en inglés, en tres regiones diferentes de México.

Otras estrategias de aprendizaje supervisado, como Redes Neuronales y Support Vector Machine han sido implementadas para el pronóstico de velocidad del viento y potencia eléctrica. Entre varios trabajos que se encuentran dentro de esta línea vale mencionar el de Sfetsos, (2002) que implementa Redes Neuronales para el pronóstico horario de viento, el trabajo de Mohandes y otros (2004) que aplica Support Vector Machines para el pronóstico diario de velocidad de viento y el trabajo de Zhou y otros, (2011), que lo implementa utilizando 3 núcleos diferentes.

Los errores documentados en los trabajos anteriormente mencionados generalmente son comparados con el de un modelo de referencia, típicamente la persistencia. Las mejoras encontradas respecto a esta metodología de referencia son dependientes del método implementado como así también de la base de datos utilizada y la región de estudio, no resultando del todo evidente cuál de todas las metodologías propuestas es superior al resto de forma generalizada.

En esta sección utilizaremos como referencia el trabajo de Brown y otros, (1984) para implementar modelos autorregresivos utilizando para ello la información de viento y potencia eléctrica de los 43 aerogeneradores que componen el PER, analizando los errores encontrados y los beneficios de la implementación de esta metodología respecto de la persistencia.

En 4.2.2 se describen metodológicamente los modelos autorregresivos, su formulación, el cálculo de sus parámetros y elección óptima del orden del modelo. En 4.2.3 se describe la base de datos utilizada y la definición de los períodos de entrenamiento y validación de los métodos formulados, mientras que la implementación de éstos para el caso de estudio con datos de viento y potencia del PER están descritos paso a paso en 4.2.4 y 4.2.5 respectivamente. La sección 4.2.6 presenta la definición del error de pronóstico y la métrica utilizada, mientras que la sección 4.2.7 plantea la formulación de un modelo simple de referencia. Los resultados obtenidos para la velocidad del viento como para la potencia eléctrica se presentan en 4.2.8 y por último en 4.2.9 se presentan las conclusiones.

4.2.2 Modelos autorregresivos

Las mediciones de temperatura, presión atmosférica y velocidad del viento, entre otras variables meteorológicas, tienden a estar temporalmente correlacionadas, exhibiendo su carácter persistente. Es esperable, por ejemplo, que la temperatura en la hora siguiente esté relacionada en cierta medida con lo que sucedió la hora anterior. Esta característica persistente nos permite estimar futuros valores que pueda adquirir esta variable conociendo sus valores presentes y pasados.

Se consideró entonces una clase de modelos paramétricos de series temporales denominados *Procesos Autorregresivos* basados en el trabajo de Box y Jenkins, (1976) que hacen uso del carácter persistente de la intensidad del viento, y que serán implementados con la finalidad de realizar predicciones temporales de esta variable en el corto plazo.

Modelo autorregresivo de orden p

Un proceso autorregresivo y estacionario de orden p ($AR(p)$) se define según la Ec.4.2.2.1.

$$x_{t+1} - \mu = \sum_{k=1}^p [\phi_k (x_{t-k+1} - \mu)] + \varepsilon_{t+1} \quad \text{Ec. 4.2.2.1}$$

Donde x es la variable de interés, μ su valor medio, ϕ_k los parámetros del modelo $AR(p)$ a estimar a partir de los datos con los que se cuenta, y ε es el error del modelo sobre el cual se asume que constituyen un proceso de “ruido blanco”; es decir que sus valores no están correlacionados y que poseen una distribución gaussiana de valor medio constante e igual a cero y una varianza conocida σ_ε^2 definida según la Ec. 4.2.2.2

$$\sigma_\varepsilon^2 = (1 - \sum_{k=1}^p \phi_k \rho_k) \sigma_x^2 \quad \text{Ec. 4.2.2.2}$$

En este caso σ_x^2 es la varianza de la variable en cuestión y ρ_k es el coeficiente de autocorrelación teórico de orden k , que puede estimarse a partir de la Ec. 4.2.2.3, considerando que $\rho_0 \equiv 1$ y conociendo los valores de los parámetros ϕ_k .

$$\rho_m = \sum_{k=1}^p \phi_k \rho_{m-k} \quad \text{Ec. 4.2.2.3}$$

Al ser un proceso estacionario en la media y la varianza, μ , σ_x^2 y σ_ε^2 no cambian en el tiempo.

Ajuste de los parámetros del modelo AR(p)

Siguiendo la descripción metodológica realizada en Wilks, (2011) sobre el ajuste del modelo $AR(p)$, la estimación de sus parámetros ϕ_k suele realizarse a partir de la resolución del sistema de ecuaciones de Yule-Walker que relaciona estos parámetros con las coeficientes de autocorrelación r_l $\{l = 1, \dots, p\}$ obtenidos a partir de la serie temporal de x , como se muestra en la Ec. 4.2.2.4.

$$\begin{aligned} r_1 &= \phi_1 + \phi_2 r_1 + \phi_3 r_2 + \dots + \phi_p r_{p-1} \\ r_2 &= \phi_1 r_1 + \phi_2 + \phi_3 r_1 + \dots + \phi_p r_{p-2} \\ r_3 &= \phi_1 r_2 + \phi_2 r_1 + \phi_3 + \dots + \phi_p r_{p-3} \\ \vdots &= \vdots + \vdots + \vdots + \dots + \vdots \\ r_p &= \phi_1 r_{p-1} + \phi_2 r_{p-2} + \phi_3 r_{p-3} + \dots + \phi_p \end{aligned} \quad \text{Ec. 4.2.2.4}$$

En este sistema de ecuaciones $\phi_k = 0 \forall k > p$.

Ejemplo para un modelo AR(1)

Aplicando la Ec. 4.2.2.1 para el caso de un modelo autorregresivo de orden 1, se obtiene la siguiente ecuación:

$$x_{t+1} - \mu = \phi_1 (x_t - \mu) + \varepsilon_{t+1} \quad \text{Ec. 4.2.2.5}$$

En donde se desprende a partir de la Ec. 4.2.2.3 y de la Ec. 4.2.2.4 que:

$$\rho_m = \phi_1^m = r_1^m \quad \text{Ec. 4.2.2.6}$$

Y la varianza del error resulta en:

$$\sigma_\varepsilon^2 = (1 - \phi_1^2) \sigma_x^2 \quad \text{Ec. 4.2.2.7}$$

Partiendo de la Ec. 4.2.2.5 se puede probar que x_{t+1} está relacionado con x_{t-1} reescribiendo la ecuación de la siguiente manera:

$$x_{t+1} - \mu = \phi_1 (\phi_1 (x_{t-1} - \mu) + \varepsilon_t) + \varepsilon_{t+1} = \phi_1^2 (x_{t-1} - \mu) + \phi_1 \varepsilon_t + \varepsilon_{t+1} \quad \text{Ec. 4.2.2.8}$$

Este procedimiento puede repetirse recursivamente probando que x_t está relacionado con $x_{t'}$ $\forall t' < t$, además de ser válido para cualquier orden de modelo autorregresivo.

Selección del orden del modelo autorregresivo

A partir del sistema de ecuaciones de Yule-Walker es posible encontrar los parámetros de cualquier modelo de orden p arbitrario. Una de las incertidumbres que surge es la determinación del orden óptimo del modelo autorregresivo a ajustar. En algún punto, aumentar la complejidad del modelo no mejorara apreciablemente la representación de los

datos, y eventualmente se produciría un sobredimensionamiento del modelo. Los criterios BIC (Schwarz, 1978) y AIC (Akaike, 1974) son utilizados frecuentemente para determinar el orden óptimo del modelo a elegir, incluyendo aquellos órdenes que minimizan la varianza de los errores, penalizando conjuntamente a éstos según la cantidad de parámetros que involucren. Las diferencias entre ambos criterios radican en la función de penalización que proponen.

$$BIC(m) = n \cdot \ln \left[\frac{n}{n-m-1} s_{\varepsilon}^2(m) \right] + (m+1) \cdot \ln(n) \quad \text{Ec. 4.2.2.9}$$

$$AIC(m) = n \cdot \ln \left[\frac{n}{n-m-1} s_{\varepsilon}^2(m) \right] + 2 \cdot (m+1) \quad \text{Ec. 4.2.2.10}$$

En las Ec. 4.2.2.9 y 4.2.2.10, n es la cantidad de datos involucrados, m el orden del modelo autorregresivo, y $s_{\varepsilon}^2(m)$ la varianza de ruido blanco estimada a partir de la Ec. 4.2.2.3 utilizando la varianza de la muestra de datos cuando n es lo suficientemente grande. Otra alternativa para estimar $s_{\varepsilon}^2(m)$ fue propuesta por Katz, (1982), la cual permite estimar recursivamente la varianza de ruido blanco de los errores de la siguiente forma:

$$s_{\varepsilon}^2(m) = [1 - \hat{\phi}_m^2] s_{\varepsilon}^2(m-1) \quad \forall m > 1 \quad \text{Ec. 4.2.2.11}$$

Considerando que $s_{\varepsilon}^2(1)$ puede calcularse a partir de la varianza muestral de la variable x de la siguiente manera:

$$s_{\varepsilon}^2(1) = [1 - r_1^2] \frac{n-1}{n-2} s_x^2 \quad \text{Ec. 4.2.2.12}$$

4.2.3 Datos: Definición de los períodos de entrenamiento y evaluación

Tal como se mencionó en la Sección 2.2 correspondiente al Capítulo 2, se contó con 2 años de datos medios horarios de velocidad y dirección de viento, y potencia eléctrica de los 43 aerogeneradores que componen el PER, con fecha de comienzo 02/04/2012.

Siguiendo la metodología propuesta en el trabajo de Brown y otros, (1984), se propondrán distintos modelos para cada estación del año de forma tal de eliminar los ciclos estacionales y analizar los resultados obtenidos destacando las diferencias encontradas en cada trimestre. Al definir los períodos de entrenamiento y de evaluación de los modelos autorregresivos debe tenerse en consideración que los trimestres escogidos en el período de entrenamiento deben ser continuos temporalmente para poder construir estos modelos representativos e independientes respecto de los meses escogidos para el período de evaluación.

Se decidió entonces definir los períodos de entrenamiento y evaluación tal como se muestra en la Tabla 4.2.3.1

2012											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2013											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2014											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre

Tabla 4.2.3.1. En azul están los meses utilizados en los distintos períodos de entrenamiento para cada trimestre del año (DEF, MAM, JJA y SON). En rojo los correspondientes al período de evaluación. Los meses sombreados en gris corresponden a aquellos en donde no se tienen datos.

Si bien la elección propuesta para los períodos de entrenamiento y evaluación se aleja de la elección más directa e intuitiva en donde se elige el período de entrenamiento en la primer parte del período total de datos y se evalúan los métodos formulados en un período posterior; en nuestro caso y para maximizar la información con la que se cuenta se decidió optar por el esquema planteado en la Tabla 4.2.3.1. Vale la pena destacar que dentro de los cuatro períodos de evaluación propuestos, los trimestres JJA y SON corresponden al año 2012, el trimestre DEF a los años 2013 y 2014 y el trimestre MAM posee dos meses correspondientes al año 2012 (Abril y Mayo), y un mes del año 2014. Este último detalle fue tenido en cuenta a la hora de evaluar los métodos propuestos.

4.2.4 Aplicación de la metodología para el caso particular del PER: VIENTO

En el Capítulo 2 se analizaron las series temporales de los aerogeneradores que componen el PER. Tanto la velocidad media como el desvío estándar presentan un ciclo diurno diferente en cada estación del año tal como lo muestran las Figuras 2.4.5 y 2.4.6 de dicho capítulo. En la presente sección se decidió mostrar el ciclo medio diurno para cada estación del año, tanto para el período de entrenamiento como de evaluación y se muestra en la Figura 4.2.4.1.

Esta estacionalidad en los ciclos diurnos motivó la formulación de modelos autorregresivos para cada una de las estaciones del año. Si bien existen diferencias entre los ciclos medios diurnos entre ambos períodos (de entrenamiento y evaluación), para los trimestres DEF, JJA y SON, existe una gran similitud en los comportamientos y son menores respecto a las encontradas en MAM.

Para complementar el análisis hecho a partir de los ciclos medios diurnos, la Figura 4.2.4.2 muestra las distribuciones de Weibull ajustadas para cada aerogenerador en cada trimestre, utilizando toda la información disponible. En la misma figura es posible observar diferencias entre las curvas a nivel intraparque y también en escala estacional. A modo de ejemplo las probabilidades de observar vientos superiores a 20 m/s se incrementan en invierno respecto a las demás estaciones, como así también aumenta la velocidad media de los aerogeneradores.

En cada trimestre tenemos una serie temporal de mediciones horarias de viento definidas de la siguiente forma:

$$U_e(t) \quad t = 1, \dots, (24 \cdot T)$$

Ec. 4.2.4.1

Donde $U_e(t)$ corresponde a la serie temporal de intensidad de viento correspondiente a la estación e del año y T la cantidad de días existente en ese trimestre en particular. De esta manera al trabajar con diferentes series para cada trimestre del año podemos tener en cuenta el ciclo estacional de velocidad del viento en el PER. La comparación entre ambos ciclos diurnos es importante porque en el siguiente paso generaremos las anomalías de viento para cada aerogenerador extrayendo el ciclo diurno medio para cada turbina eólica considerando únicamente la información contenida en el período de entrenamiento, y éstos valores medios serán aplicados también en el período de evaluación. Esta decisión implica entonces la introducción de un error extra al momento de reconstruir los pronósticos de viento en el período de evaluación, principalmente en el trimestre MAM donde las diferencias entre los ciclos medios diurnos entre ambos períodos es mayor.




Figura 4.2.4.1. Ciclo medio diurno de la velocidad del viento para cada estación del año, para los períodos de entrenamiento (verde) y evaluación (rojo). El sombreado muestra el rango adquirido considerando los 43 aerogeneradores, y las líneas punteadas sus valores medios.

El siguiente paso consiste en eliminar el ciclo medio diurno de $U_e(t)$ para cada aerogenerador y estación del año. Para ello tomamos el valor medio horario de las series ($\mu_e(t)$) calculado en

el período de entrenamiento y se lo restamos a las series temporales de en ambos períodos para obtener las anomalías, como se encuentra representado en la Ec. 4.2.4.2.

$$U_e^*(t) = U_e(t) - \mu_e(t) \quad t = 1, \dots, (24 \cdot T) \quad \text{Ec. 4.2.4.2}$$

En donde se asume que $\mu_e(t)$ es una función periódica donde $\mu_e(t) = \mu_e(t + 24) \forall t \in [1; 24 * (T - 1)]$.




Figura 4.2.4.2. Distribuciones teóricas de Weibull ajustadas en cada uno de los 43 aerogeneradores del PER para cada estación del año.

De ahora en adelante se trabajará con las anomalías y se aplicarán los pasos inversos para conseguir la variable original que es la velocidad del viento.

Implementación de modelos autorregresivos para las series temporales de anomalías de INTENSIDAD DEL VIENTO

Para cada trimestre el año y para cada uno de los 43 aerogeneradores del PER se propusieron modelos autorregresivos de distintos órdenes utilizando las series $U_e^*(t)$ dentro del período de entrenamiento, y se estimaron los parámetros de cada uno de estos modelos a través de la resolución del sistema de ecuaciones de Yule-Walker descrito en la Ec. 4.2.2.4.

Luego se determinó el orden óptimo del modelo para cada aerogenerador y estación del año, como aquel que minimiza el criterio AIC formulado en la Ec. 4.2.2.10.

La Figura 4.2.4.3 presenta el orden óptimo del modelo encontrado en cada aerogenerador para cada estación del año. Se destaca en esta figura que en los meses de verano y primavera hay mayor homogeneidad espacial en la selección del orden óptimo del modelo respecto de

los meses de otoño e invierno. Sin embargo y por simplicidad, se propuso para cada trimestre un modelo cuyo orden único corresponde a la moda de los órdenes encontrados para cada estación del año, proponiendo entonces para el trimestre DEF un modelo AR(4) (o también denominado de ahora en más AR4), un modelo AR3 para MAM, un modelo AR4 para el invierno y un AR5 para la primavera.

La Figura 4.2.4.4 muestra el autocorrelograma para el aerogenerador 43 y los procesos autorregresivos AR1 y ARp para cada estación del año. Se observa en esta figura el carácter persistivo del viento y el mejor ajuste a este proceso por parte de los modelos autorregresivos de orden superior respecto al AR1.

Siguiendo esta misma línea de razonamiento y a modo de ejemplo, la Figura 4.2.4.5 muestra el autocorrelograma de los residuos de los modelos autorregresivos propuestos en cada trimestre del año, y su comparación con un modelo autorregresivo de orden 1 (AR1) a fines de observar la mejora introducida al considerar un orden mayor.

Los autocorrelogramas de los residuos de aquellos modelos de orden superior muestran su característica aleatoria no estando autocorrelacionados entre sí, salvo para el lag 12 en las estaciones de otoño e invierno, en las cuales los valores de autocorrelación superan levemente las bandas de significancia. Los modelos AR1 no serían los más adecuados ya que se observa una dependencia temporal significativa en los primeros plazos de pronóstico para todas las estaciones del año que no es tenida en cuenta por el proceso AR1 y puede ser removida mediante la proposición de modelos de órdenes superiores.

Finalmente la Tabla 4.2.4.1 resume los pasos realizados para las series temporales de viento de cada aerogenerador, en cada estación del año, aplicadas en el período de entrenamiento.

a) Definimos las series temporales de viento $U_e(t) \quad t = 1, \dots, (24 \cdot T)$ b) Le sacamos el ciclo medio diurno a la variable normalizada obteniendo: $U_e^*(t) = U_e(t) - \mu_e(t) \quad t = 1, \dots, (24 \cdot T)$ c) Calculamos los parámetros ϕ_k del modelo autorregresivo de orden p ($AR(p)$) óptimo según criterio AIC, utilizando la serie temporal de $U_e^*(t)$

Tabla 4.2.4.1. Resumen de los pasos realizados hasta la construcción de modelos autorregresivos de orden p , para cada estación del año y aerogenerador.




Figura 4.2.4.3. Orden óptimo del modelo autorregresivo propuesto para cada aerogenerador en cada estación del año, para la intensidad del viento. La selección del orden óptimo fue realizada a partir del criterio AIC.




Figura 4.2.4.4. Autocorrelogramas del viento y procesos autorregresivos para los modelos AR1 y los modelos de orden óptimo encontrados para cada estación del año. Los gráficos fueron realizados utilizando las series temporales del aerogenerador número 43 del PER.




Figura 4.2.4.5. Autocorrelogramas de los residuos para los modelos AR1 y los modelos de orden óptimo encontrados para cada estación del año. Los gráficos fueron realizados utilizando las series temporales del aerogenerador número 43 del PER.

4.2.5 Aplicación de la metodología para el caso particular del PER: POTENCIA ELÉCTRICA

Análogamente a los pasos realizados para el viento, los mismos fueron implementados para la potencia eléctrica, utilizando las series temporales de potencia medidas en cada aerogenerador. Se obtiene entonces en cada estación del año e una serie temporal de mediciones horarias de potencia eléctrica definidas de la siguiente forma:

$$P_e(t) \quad t = 1, \dots, (24 \cdot T) \quad \text{Ec. 4.2.5.1}$$

Dado que se requiere trabajar con las anomalías de potencia, se calcularon los ciclos medios diurnos de potencia eléctrica para los períodos de entrenamiento y evaluación. La Figura 4.2.5.1 muestra estos ciclos para cada estación del año.




Figura 4.2.5.1. Ciclo medio diurno de la potencia eléctrica para cada estación del año, para los períodos de entrenamiento (verde) y evaluación (rojo). El sombreado muestra el rango adquirido considerando los 43 aerogeneradores, y las líneas punteadas sus valores medios.

Nuevamente y en términos medios, las mayores diferencias entre los ciclos medios diurnos de potencia eléctrica se observan en el trimestre MAM.

Al igual que lo realizado para la velocidad del viento, se procedió a eliminar el ciclo medio diario de $P_e(t)$ para cada aerogenerador y estación del año utilizando los valores encontrados en el período de entrenamiento. En este caso la Ec. 4.2.4.2 resulta en:

$$P_e^*(t) = P_e(t) - \mu_e(t) \quad t = 1, \dots, (24 \cdot T) \quad \text{Ec. 4.2.5.2}$$

En donde $\mu_e(t)$ corresponde al valor medio horario de potencia eléctrica calculado en el período de entrenamiento.

Así como la Tabla 4.2.4.1 resume los pasos realizados para las series temporales de viento de cada aerogenerador, en cada estación del año, aplicadas en el período de entrenamiento, la Tabla 4.2.5.1 lo hace para la potencia eléctrica.

a) Definimos las series temporales de viento $P_e(t) \quad t = 1, \dots, (24 \cdot T)$ b) Le sacamos el ciclo medio diario a la variable normalizada obteniendo: $P_e^*(t) = P_e(t) - \mu_e(t) \quad t = 1, \dots, (24 \cdot T)$ c) Calculamos los parámetros ϕ_k del modelo autorregresivo de orden p ($AR(p)$) óptimo según criterio AIC, utilizando la serie temporal de $P_e^*(t)$

Tabla 4.2.5.1. Resumen de los pasos realizados hasta la construcción de modelos autorregresivos de orden p , para cada estación del año y aerogenerador, para la potencia eléctrica.

Implementación de modelos autorregresivos para las series temporales de anomalías de POTENCIA ELÉCTRICA

Si bien la velocidad del viento y la potencia eléctrica están vinculadas entre sí, esta relación además de ser no-lineal, adquiere características propias asociadas a la forma de la curva de potencia. Es esperable entonces que los modelos autorregresivos formulados para las anomalías de potencia eléctrica sean diferentes a los encontrados para el viento, no sólo en los parámetros que los conforman, sino también en el orden óptimo encontrado de los modelos calculados para cada estación del año. De hecho y siguiendo el criterio AIC, se encontró que el modelo óptimo para el trimestre DEF es un AR4, para MAM un AR5, un AR9 para JJA y un modelo AR7 para SON. El carácter persistivo de la potencia eléctrica en invierno se hace aún más fuerte estando relacionado el valor actual de potencia con lo sucedido 9 horas antes.




Figura 4.2.5.2. Autocorrelogramas de los residuos para los modelos AR1 y los modelos de orden óptimo de la potencia eléctrica encontrados para cada estación del año para el aerogenerador número 43.

Los autocorrelogramas de los residuos de estos modelos y de los calculados para un AR1 en cada estación del año y para el aerogenerador número 43 se presentan en la Figura 4.2.5.2. En este caso los modelos de orden superior no muestran ninguna autocorrelación de los residuos para ningún lag en particular, quedando siempre dentro de las bandas de significancia del 95%.

Generación de pronósticos de potencia eléctrica en el período de evaluación utilizando los modelos $AR(p)$ formulados para cada estación del año en el período de entrenamiento

Se siguió la misma implementación descrita para la intensidad del viento, aunque considerando ahora los modelos autorregresivos calculados para la potencia eléctrica.

4.2.6 Métrica del error de pronóstico de intensidad del viento y potencia eléctrica

De forma análoga a lo descrito en la Sección 3.2.7 del Capítulo 3, se define el error de pronóstico del viento para cada aerogenerador como:

$$\epsilon_e(t_0 + k|t_0) = \hat{U}_e(t_0 + k|t_0) - U_e(t_0 + k) \quad \text{Ec. 4.2.6.1}$$

Donde $\hat{U}_e(t_0 + k|t_0)$ es el pronóstico de viento en la estación del año e inicializado en el tiempo t_0 , mientras que $U_e(t_0 + k)$ es el viento observado para ese mismo plazo de pronóstico k .

Luego construimos una métrica de error característica como es el RMSE, definida según las Ec. 4.2.6.2.

$$RMSE(k) = \sqrt{\frac{1}{N} \sum_{i=1}^N \epsilon_e^2(t_0 + k|t_0)} \quad \text{Ec. 4.2.6.2}$$

Este mismo razonamiento se aplica para la potencia eléctrica, con la siguiente salvedad:

Se divide el $RMSE(k)$ encontrado para cada aerogenerador por la máxima potencia del aerogenerador Vestas V90, y se lo multiplica por 100 para obtener lo que se denomina $NRMSE$ y cuyas unidades son porcentuales. La Ec. 4.2.6.3 presenta la definición de $NRMSE$.

$$NRMSE(k) = 100 * \frac{RMSE(k)}{1800} \quad \text{Ec. 4.2.6.3}$$

Esta normalización del índice permite comparar los valores encontrados para el caso particular del PER con otras metodologías y parques eólicos del mundo.

4.2.7 Comparación con respecto a un modelo simple de referencia

Es muy común la comparación del desempeño de algún método de pronóstico de viento o potencia de cierta complejidad con respecto al desempeño de algún modelo de referencia de formulación sencilla y que además presente buenos resultados. En particular y para plazos de pronósticos del orden de horas es común utilizar a la persistencia como método de pronóstico a vencer. Si bien su formulación es muy simple, es difícil superar su desempeño para esos plazos de pronóstico debido a la evolución lenta de las variables meteorológicas involucradas en el análisis. Análogamente a lo realizado para los modelos autorregresivos, se decidió tener en cuenta el ciclo medio diurno para el modelo de referencia, de forma tal de realizar una comparación más precisa entre ambos modelos.

La Ec. 4.2.7.1 presenta la formulación general del modelo de pronóstico persistente.

$$\begin{aligned} X(t_0 + k|t_0) &= X(t_0) + (\mu_e(t_0 + k) - \mu_e(t_0)) \quad \forall X(t_0 + k|t_0) \geq 0 \\ X(t_0 + k|t_0) &= 0 \quad \forall X(t_0 + k|t_0) < 0 \end{aligned} \quad \text{Ec. 4.2.7.1}$$

En el caso particular del presente análisis, $X(t_0)$ corresponde a la observación de viento o potencia eléctrica en el tiempo inicial de pronóstico en cada aerogenerador y estación del año, y nuevamente $\mu_e(t)$ corresponde al valor medio de $X(t)$ para cada hora del día, calculada en el período de entrenamiento.

4.2.8 Resultados

La Figura 4.2.8.1 muestra el RMSE de la intensidad del viento en función del plazo de pronóstico para los modelos autorregresivos y para el modelo persistente de referencia, formulados en cada estación del año y aerogenerador.

Rápidamente pueden destacarse algunas características en la comparación del RMSE entre los modelos autorregresivos y la persistencia. En principio, para el primer plazo de pronóstico, el RMSE crece velozmente alcanzando valores cercanos a 1.5 m/s para ambos modelos, con muy poca dispersión entre aerogeneradores. Por otro lado y observando el comportamiento medio del PER (línea punteada), resulta que el beneficio de la implementación de modelos autorregresivos respecto del modelo de referencia aumenta en la estación estival y en la primavera, disminuyendo levemente en otoño, siendo el trimestre JJA el que mayores errores produce, acercándose más a los errores producidos por la persistencia.

La Figura 4.2.8.2 muestra la mejora en el RMSE de los pronósticos de velocidad de viento realizados a través de los distintos modelos autorregresivos propuestos para cada estación del año, respecto de los valores encontrados para el modelo de referencia.

En los dos primeros trimestres del año (DEF y MAM) la mejora en el desempeño de los modelos autorregresivos respecto a la persistencia se evidencia para todos los aerogeneradores e incluso existe una menor dispersión de los errores relativos, mientras que en los dos trimestres restantes eso no ocurre en los primeros plazos de pronóstico para la totalidad de turbinas que componen el PER. Complementariamente en primavera y verano se

observan mejoras mayores respecto a los meses de otoño e invierno para todos los plazos de pronóstico. Es en la estación invernal en la que se observan los menores beneficios de utilizar modelos autorregresivos para pronosticar el viento. Esto podría deberse a que el viento es más persistente en esa estación del año, coincidente con el corrimiento al norte de los vientos oeste.




Figura 4.2.8.1. RMSE del viento en función del plazo de pronóstico de los modelos autorregresivos (verde) y del modelo de referencia (rojo), formulados para cada aerogenerador y estación del año. El sombreado marca los errores máximos y mínimos considerando los 43 aerogeneradores, mientras que la línea punteada indica el valor medio.




Figura 4.2.8.2. Diferencia relativa del RMSE de la velocidad del viento para el modelo de referencia, respecto del RMSE de los modelos autorregresivos, en función del plazo de pronóstico. El sombreado marca los valores máximos y mínimos considerando los 43 aerogeneradores, mientras que la línea punteada indica el valor medio.

El mismo análisis se hizo para la potencia eléctrica. En este caso los resultados obtenidos se presentan en las Figuras 4.2.8.3 y 4.2.8.4. Los resultados encontrados para esta variable son similares a los hallados para la intensidad del viento, aunque la mayor diferencia radica en la

menor dispersión de los errores entre aerogeneradores, lo que resalta aún más la efectividad de los modelos autorregresivos.




Figura 4.2.8.3. NRMSE de la potencia eléctrica en función del plazo de pronóstico de los modelos autorregresivos (verde) y del modelo de referencia (rojo), formulados para cada aerogenerador y estación del año. El sombreado marca los errores máximos y mínimos considerando los 43 aerogeneradores, mientras que la línea punteada indica el valor medio.




Figura 4.2.8.4. Diferencia relativa del RMSE de la potencia eléctrica para el modelo de referencia, respecto del RMSE de los modelos autorregresivos, en función del plazo de pronóstico. El sombreado marca los valores máximos y mínimos considerando los 43 aerogeneradores, mientras que la línea punteada indica el valor medio.

Finalmente la Tabla 4.2.8.1 muestra la disminución relativa del RMSE de los modelos autorregresivos respecto de los valores hallados para el modelo de referencia para las cuatro estaciones del año y distintos plazos de pronóstico. Todos los valores son positivos indicando

una mejora del desempeño de los pronósticos realizados con los modelos autorregresivos respecto de los pronósticos basados en el modelo persistivo de referencia.

	Trimestre	+1 hr	+2 hr	+3 hr	+6 hr	+12 hr
Viento	DEF	4.8 %	9.1 %	12.6 %	20.1 %	27.4 %
	MAM	3.2 %	5.9 %	8.1 %	13.5 %	21.4 %
	JJA	1.9 %	4.6 %	6.9 %	11.6 %	16.6 %
	SON	3.6 %	7.3 %	10.9 %	19.0 %	24.2 %
Potencia	DEF	5.5 %	9.7 %	13.5 %	21.2 %	28.4 %
	MAM	3.2 %	6.0 %	8.5 %	13.9 %	21.5 %
	JJA	3.8 %	7.3 %	9.2 %	13.0 %	17.7 %
	SON	3.9 %	7.7 %	11.0 %	19.0 %	24.8 %

Tabla 4.2.8.1. Disminución relativa del RMSE de los modelos autorregresivos respecto de los valores encontrados para el modelo de referencia.

4.2.9 Conclusiones de la sección

Los resultados presentados en la sección 4.2.8 muestran el beneficio de la implementación de estos modelos autorregresivos como método de pronóstico de la evolución temporal del viento y de la potencia eléctrica respecto del modelo persistivo.

El desempeño de los modelos autorregresivos cuyo orden óptimo fue seleccionado a través del criterio AIC fue superior al del modelo de referencia para las 4 estaciones del año tanto para la intensidad del viento como para la potencia eléctrica. Los trimestres de primavera y verano mostraron un mayor beneficio de la aplicación de los modelos AR respecto de la implementación del modelo de referencia disminuyendo el RMSE y NRMSE en más del 10% para la tercera hora de pronóstico. Por el contrario, los trimestres JJA y MAM tuvieron resultados más cercanos al desempeño del modelo de referencia para todos los plazos de pronóstico.

El trabajo de Torres y otros, 2005 presenta la mejora en el RMSE de los pronósticos de viento realizados a través de un modelo ARMA, respecto de la persistencia, para distintos plazos de pronóstico, considerando todas las estaciones del año y varias estaciones meteorológicas. Para un plazo de pronóstico de una hora, la mejora es levemente menor a 4% si se consideran 5 estaciones meteorológicas analizadas, valor que es muy similar al encontrado en esta sección de la Tesis. Asimismo el trabajo de Sfetsos, (2002) que implementa redes neuronales para realizar pronósticos de velocidad de viento presenta valores similares si se trabaja con datos horarios (mejoras entre un 2% y un 5%), que aumentan considerablemente si se trabaja con datos diezminutales, alcanzando valores entre 10% y 20% de mejora respecto al RMSE encontrado para el modelo de referencia basado en la persistencia.

La metodología implementada en esta sección fue realizada con el objeto de analizar los errores de los pronósticos de viento y potencia eléctrica utilizando modelos autorregresivos en un contexto fuera de línea. Para ello se consideró un período de entrenamiento y uno de validación fijos en donde se asumió que el ciclo medio diurno calculado en el primer período

era representativo también del segundo. En un entorno operativo sería deseable actualizar el ciclo medio diurno considerando por ejemplo los últimos tres meses de información disponible para obtener las anomalías de las variables de interés, actualizando el orden de los modelos y los parámetros que los conforman para luego realizar las predicciones temporales de estas variables. Esta actualización podría ser diaria o semanal dada su bajo costo computacional y velocidad de ejecución. Adicionalmente es posible trabajar directamente con la variable potencia eléctrica, independizándose de los pronósticos de velocidad de viento y su transformación a potencia, evitando los errores inherentes a esta transformación.

4.3 Pronósticos a corto plazo – Método basado en modelos lineales espaciotemporales

4.3.1 Introducción y antecedentes

En la Sección 4.2.1 se introdujo un conjunto de metodologías aplicadas por diferentes autores basadas en análisis de series temporales con el fin de pronosticar el viento y la potencia eléctrica para plazos inferiores a 6 hs. Estas metodologías utilizan información de la serie histórica de viento y de las últimas mediciones disponibles, permitiendo predecir su evolución futura con resultados superiores a un modelo de referencia como la persistencia. En particular en la Sección 4.2 de esta Tesis se aplicaron modelos autoregresivos que aprovechan la correlación temporal que presenta esta variable como así también la potencia eléctrica.

Existe otro acercamiento al problema del pronóstico de viento para corto plazo, también basado en métodos estadísticos. En este caso se pretende utilizar información de las observaciones en el sitio de interés y también de las estaciones aledañas, aprovechando la correlación espaciotemporal del viento.

Diversos autores han probado los beneficios de la implementación de modelos de pronóstico espaciotemporales. El trabajo de Donousis y otros, (2004) implementa un modelo difuso (más conocido como Fuzzy Model) para el pronóstico de viento y generación de potencia utilizando la buena correlación espacial existente entre distintas estaciones aledañas entre sí, con un distanciamiento máximo de 30km. Para un plazo de pronóstico de una hora, este tipo de modelo supera el desempeño de la persistencia en alrededor de 21% y 13% para los casos de estudios localizados en una región con menor y mayor complejidad topográfica respectivamente. El trabajo de Hering y Genton, (2010) propone distintos modelos lineales utilizando información de distintas estaciones meteorológicas los cuáles fueron especificados según el régimen de viento dominante. Los resultados obtenidos muestran desempeños mejores respecto al modelo de referencia para plazos de 2 horas, para distintos meses del año. En Dowell y otros, (2014) se propone un modelo espaciotemporal para el pronóstico de viento utilizando regímenes de dirección continua del viento. Nuevamente los resultados obtenidos utilizando la información de estaciones cercanas a los sitios de interés muestran errores menores respecto de los encontrados para la persistencia, y para plazos que van entre 1 y 6 horas. En Suryawanshi y Ghosh, (2015) utilizan la covarianza espaciotemporal de estaciones meteorológicas ubicadas en Irlanda con el propósito de predecir la velocidad media diurna del viento y la potencia eólica, para un plazo de pronóstico de 48 hs, y también para plazos de 10 semanas y hasta 3 meses. Vale destacar también el trabajo de Tastu y otros, (2010), el cual tiene como objetivo modelar la propagación espaciotemporal de los errores en los pronósticos de potencia eléctrica mediante la proposición de modelos lineales estimados para distintos regímenes de viento.

La región noreste patagónica no cuenta con un número considerable de estaciones meteorológicas debido entre otras cosas, a la baja densidad de población que presenta la Provincia de Chubut, la cual a su vez está concentrada en pocos centros urbanos. Si bien existen datos de estaciones meteorológicas en las ciudades de Trelew, Rawson y Puerto Madryn; estas localidades se encuentran al norte del PER, y no existen estaciones meteorológicas al sur del parque eólico, al menos hasta la ciudad de Comodoro Rivadavia ubicada aproximadamente 400 km al sur del PER. Por este motivo en esta sección se propone

un experimento teórico a partir del cual se simulan las condiciones de viento en capas bajas para la región patagónica, considerando cada punto de retícula del dominio como una estación meteorológica. El punto de retícula más cercano al PER representará la serie temporal de este parque eólico. El objetivo principal de este experimento es proponer distintos modelos espaciotemporales de predicción de intensidad de viento en el PER para distintos plazos de pronóstico y regímenes de viento determinados a partir de la combinación entre la velocidad y la dirección del viento, encontrando aquellos predictores que disminuyen el error de los pronósticos respecto de un modelo sencillo basado en la persistencia del viento.

El trabajo está dividido de la siguiente manera: En la Sección 4.3.2 se realiza una descripción de las simulaciones, mientras que la Sección 4.3.3 presenta la configuración del modelo WRF escogida. En 4.3.4 se formulan los modelos espaciotemporales propuestos en este estudio mientras que en 4.3.5 se plantea la selección de regímenes de viento, la selección de los predictores y la estimación de sus coeficientes. Los resultados obtenidos en este experimento son presentados en la Sección 4.3.6, y finalmente en 4.3.7 se presentan las conclusiones.

4.3.2 Descripción general de la simulación

Se realizó una simulación de 90 días de duración utilizando el modelo WRF con el objeto de generar campos de viento en toda la región noreste patagónica. La fecha de inicio de la simulación es el 18/05/2013, finalizando el 18/08/2013. Se utilizaron como condiciones iniciales y de borde los análisis del modelo GFS, disponibles cada 6 horas y cuya resolución espacial es de 0.5°. La elección de este trimestre radicó en que estamos en el momento del año donde el ciclo medio diurno presenta una amplitud menos marcada (casi inexistente), siendo además el trimestre del año donde el viento proviene con mayor frecuencia de todo el cuadrante oeste. Es en todo este cuadrante donde los pronósticos de dirección de viento del WRF presentaban los menores valores de RMSE, cuando estos se comparaban con las mediciones de dirección de viento del PER, como se detalló en la Sección 3.3.3. Si bien el experimento de esta sección está basado en una simulación, queremos que ésta sea lo más realista posible en la representación del viento en los alrededores del PER.

4.3.3 Configuración del modelo WRF

Se utilizó la misma configuración del modelo WRF propuesta para la configuración *Ctrl* del Capítulo 3 (Sección 3.2.5), incluyendo el mismo dominio (D-BR), parametrizaciones, espaciamiento horizontal entre puntos de retícula y niveles verticales.

Se guardaron únicamente los campos de viento a 10m de todo el dominio, con una frecuencia temporal de 10 minutos. Es decir que al final de la simulación contábamos con 12960 datos de intensidad y dirección de viento para cada punto de retícula del dominio.

El dominio propuesto es sustancialmente mayor al área de interés; es por eso que se decidió recortar el área de los campos de salida considerando únicamente una retícula de 41 puntos en la dirección este-oeste y 41 puntos en la dirección norte-sur, centrada en el punto de

retícula más cercano a la localización geográfica del PER, considerando además la serie temporal de este punto, como la serie “observada” de viento para este parque eólico.

De ahora en adelante, cada vez que se mencione la serie observada en determinada posición geográfica, se referirá a la serie temporal simulada con el modelo WRF para ese punto de retícula.

4.3.4 Modelos espacio-temporales para distintos regímenes de viento

Se propuso el siguiente modelo múltiple lineal para predecir la velocidad del viento en el punto de retícula más cercano al PER, para plazos de pronóstico que van de 10 min a 6 horas:

$$V_{s_0}(G, k) = a_0(G, k) + \sum_{s=1}^{N_s} \sum_{d=1}^6 a_{s,d}(G, k) \cdot V_{s,d}(G, t_0 - d + 1) + \varepsilon_{s_0}(G, k) \quad \text{Ec. 4.3.4.1}$$

En esta ecuación s corresponde a los distintos puntos de retícula del dominio recortado, siendo s_0 la posición más cercana al PER, mientras que N_s representa la totalidad de puntos de retícula considerados en el dominio ($N_s = 41^2 = 1681$). $V_{s_0}(G, k)$ es el pronóstico de viento en el PER, para un plazo de pronóstico k , y para cada uno de los 9 regímenes de viento G que se describirán en la Sección 4.3.5.1. Dado el tiempo inicial de pronóstico t_0 , el término $V_{s,d}(G, t_0 - d + 1)$ corresponde al viento del punto de retícula s del dominio bajo el régimen de viento G , observado en el tiempo $t_0 - d + 1$, siendo d un desfase temporal a intervalos de 10 min. Entonces, para los modelos formulados en la Ec. 4.3.4.1, se propusieron N_s predictores espaciales, cada uno de ellos desfasados hasta 5 tiempos sumado al último viento observado en el tiempo t_0 , ($d = 1, \dots, 6$). Es decir que una vez fijado el régimen de viento (G), en la ecuación 4.3.4.1 pueden identificarse 10.086 potenciales predictores ($41 \cdot 41 \cdot 6$). Vale destacar que dentro de los potenciales predictores se encuentran las observaciones para el tiempo inicial de pronóstico y aquellas desfasadas, para el punto de retícula más cercano al PER. Finalmente $a_0(G, k)$ y $a_{s,d}(G, k)$ son los coeficientes del modelo múltiple lineal propuesto que deben estimarse para cada régimen de viento y plazo de pronóstico, y el término $\varepsilon_{s_0}(G, k)$ corresponde al residuo de los modelos múltiples lineales, del que se asume que presentan una distribución Gaussiana con media igual a cero y varianza constante $\sigma_\varepsilon^2(G, k)$.

Los modelos propuestos en la Ec. 4.3.4.1 son similares a aquellos formulados en el trabajo de Hering y Genton, (2010), en donde los valores pronosticados del predictando son el resultado de una combinación lineal de distintos predictores ubicados en otros sitios y desfasados temporalmente, bajo distintos regímenes. Asimismo, si solo se consideran aquellos predictores correspondientes al punto de retícula más cercano al PER, estamos en presencia de un modelo temporal, el cual es un caso específico de los modelos espaciotemporales formulados en esta sección.

4.3.5 Inferencia del modelo

4.3.5.1 Selección de regímenes de viento

Se propusieron distintos regímenes de viento que combinan la dirección y velocidad del viento observada en el tiempo presente (inicialización de los pronósticos), en el PER. Para llevar a cabo esto, en el presente estudio se calcularon los terciles de ambas variables por separado, delimitando sus intersecciones 9 grupos o regímenes.

Si bien se podría haber optado únicamente por delimitar los regímenes utilizando la dirección del viento, la introducción de la velocidad nos permite encontrar distintas dependencias entre lo que sucede en el PER respecto de otros sitios ubicados en el dominio.

Entre otros elementos, la motivación para incluir predictores espaciotemporales bajo distintos regímenes de viento puede visualizarse en la Figura 4.3.5.1.1. En esta se presentan 3 evoluciones temporales para tres puntos distintos del dominio propuesto. La línea negra continua representa la serie temporal en el PER, mientras que las curvas continuas azules y rojas lo hacen para puntos ubicados 100 km y 200 km al sur del PER respectivamente. Las líneas verticales punteadas señalan el momento de máxima velocidad del viento para cada serie.




Figura 4.3.5.1.1: Evoluciones temporales de intensidad de viento para el punto de retícula del dominio más cercano al PER (línea continua negra), y para dos puntos ubicados a 100km (azul) y 200 km (rojo) al sur del per respectivamente. Las líneas verticales punteadas señalan el momento de máxima velocidad del viento para cada serie.

La selección temporal escogida para la realización de la figura coincide con el paso de un sistema frontal en la localización del PER. Asociado a la ocurrencia del máximo del viento es interesante notar que éste ocurre en tiempos anteriores para los puntos de retícula ubicados al sur del parque eólico, representando el avance del sistema en su movimiento hacia el norte de la región. Si bien el modo en que se seleccionan los regímenes de viento no permitiría detectar cambios entre regímenes (ya que la selección se realiza en función de la velocidad y dirección observada en el PER en el tiempo inicial de pronóstico), una vez que el sitio de interés esté inmerso dentro del flujo dominante es posible utilizar predictores ubicados en diferentes sitios y desfasados temporalmente para pronosticar con mejor desempeño la velocidad del viento en el PER, anticipando con cierto grado de precisión los cambios en la velocidad del viento antes que éstos lleguen a la posición del parque eólico. Es de esperar entonces que algunos de los predictores seleccionados bajo un régimen de viento con componente sur, se encuentren al sur del PER, aunque otros predictores localizados en otras partes de la región pueden quedar seleccionados por el método de selección de predictores que propondremos en la Sección 4.3.5.2, ya que el método en sí selecciona aquellos predictores que disminuyen el error de pronóstico y no responden necesariamente a un proceso físico del tipo advectivo.

Respecto a la dirección del viento, la Figura 4.3.5.1 muestra la rosa de los vientos del punto de retícula más cercano a la ubicación del PER. De forma similar a lo observado con las mediciones reales de dirección del viento del parque eólico para la misma estación del año, se observa una ausencia casi absoluta de vientos provenientes de todo el cuadrante este. Los regímenes propuestos tendrán entonces una marcada componente del sector oeste.

Habiendo considerado tanto la velocidad como la dirección del viento en la selección de los regímenes, la Figura 4.3.5.2 muestra los distintos grupos encontrados en nuestro experimento. Esta figura presenta en sombreado los 3 sectores principales de dirección del viento; las líneas punteadas esquematizan los terciles de velocidad, y las flechas blancas indican la dirección principal del viento en cada sector de dirección. De esta manera quedaron determinados 9 grupos (G1, G2,..., G9). El primer sector de dirección abarca las direcciones de viento comprendidas entre 115° y 265°; el segundo entre 265° y 300°, y el tercer sector contiene el rango de direcciones restante. El segundo sector asociado a los grupos G4, G5 y G6 posee un rango mucho menor debido a la frecuencia alta de ocurrencia de vientos provenientes de estas direcciones. Respecto a los valores de los terciles de velocidad de viento, estos corresponden a 5.3 m/s y 7.5 m/s respectivamente, de forma tal que los vientos menores al primer tercil serán considerados vientos “leves” (G1, G4 y G7), vientos “moderados” serán aquellos comprendidos entre el primer y segundo tercil (G2, G5 y G8), y vientos “fuertes” aquellos superiores al segundo tercil (G3, G6 y G9).

Recordando que en esta estación del año prácticamente no ocurren eventos de todo el cuadrante Este, es por eso que la dirección principal de viento del Sector 3 corresponde a vientos del noroeste.




Figura 4.3.5.1.2. Rosa de los vientos para el punto de retícula del dominio más cercano a la localización del PER.




Figura 4.3.5.1.3. Regímenes de viento propuestos a partir de la información de dirección y velocidad del punto de retícula más cercano al PER. Los sectores sombreados corresponden a la delimitación direccional. Las líneas punteadas corresponden a los terciles de velocidad. Las flechas blancas indican la dirección principal de cada sector de dirección.

4.3.5.2 Selección de predictores: Stepwise y estimación de los coeficientes de los modelos

Selección de predictores

Stepwise es una metodología de selección de predictores muy desarrollada en diversos libros de estadística. En esta sección se dará una breve introducción a la metodología, la cual fue tomada de Wilks, (2011) y adaptada para el presente experimento.

Supongamos que se tienen M predictores candidatos (en nuestro caso $M = 10.086$) para un modelo múltiple lineal. Se comienza el proceso de selección hacia adelante proponiendo el siguiente modelo dentro del período de entrenamiento propuesto:

$$\hat{y} = a_0 \quad \text{Ec. 4.3.5.2.1}$$

Este primer modelo está construido únicamente por la ordenada al origen, que coincide además con el valor promedio de nuestro predictando. En el primer paso de selección de predictores, todos los M potenciales predictores son examinados, y aquel predictor que presente la mejor regresión lineal con el predictando, es escogido. De esta manera, para el primer paso de la selección, el modelo múltiple lineal resulta en:

$$\hat{y} = a_0 + a_1x_1 \quad \text{Ec. 4.3.5.2.2}$$

En este caso a_0 dejará de ser el valor promedio de nuestro predictando.

En el siguiente paso, un nuevo predictor es escogido entre los $M-1$ potenciales predictores restantes. El nuevo predictor escogido es aquel que presenta la mejor regresión lineal del siguiente modelo, con máximo valor de R^2 , menor Error Cuadrático Medio (o MSE por sus siglas en inglés), y mayor cociente de F:

$$\hat{y} = a_0 + a_1x_1 + a_2x_2 \quad \text{Ec. 4.3.5.2.3}$$

Nuevamente los valores de a_0 y a_1 no necesariamente serán iguales a los estimados en el paso anterior.

Esto se repite recursivamente, agregando un nuevo predictor en cada paso, debiéndose estimar los coeficientes lineales que estén incluidos en su formulación.

Estimación de los parámetros

Para el primer paso del método de Stepwise, debemos estimar un parámetro (Ec. 4.3.5.2.1), mientras que para el paso N de iteración del método, $N+1$ coeficientes del modelo múltiple lineal propuesto deben ser estimados para encontrar los valores de los parámetros que acompañan a los predictores seleccionados por la metodología. Para este tipo de modelos, la estimación de sus parámetros puede realizarse encontrando aquellos valores que minimizan el MSE de los residuos del modelo a través de Cuadrados Mínimos, lo que permite además encontrar una expresión única de la estimación de los coeficientes. Existe una vasta literatura en libros de estadística clásica que aborda la estimación de parámetros para modelos múltiple lineales, de las cuales podemos nombrar el libro de Wilks, (2011), y Madsen, (2008) que lo trabajan de diferente manera y que fueron seguidos en la presente Tesis.

Reglas de detención

Stepwise requiere un criterio de detención. Sin esta regla, la metodología de selección avanzaría hasta generar un modelo múltiple lineal que incluya los M potenciales predictores, pudiendo sobredimensionar la cantidad de predictores necesarios para construir un modelo que sirva además para ser empleado en un set de datos independiente.

Uno de los criterios de detención comúnmente utilizado está basado en el MSE. Esta elección es intuitivamente atractiva ya que la raíz de esta variable (RMSE) refleja la precisión de una regresión.

Si el número de predictores es sustancialmente menor al tamaño de la muestra, agregar nuevos predictores (incluyo aquellos que carezcan de sentido) disminuirá el MSE en el conjunto de datos de construcción del modelo. Sin embargo, para un conjunto de datos independiente al de construcción, llamado período de evaluación o validación, en algún punto el agregado de nuevos predictores incrementará el valor de MSE. Este resultado no es sorprendente ya que la metodología de cuadrados mínimos mediante la cual se calculan los coeficientes del modelo múltiple lineal es óptima en la minimización del MSE para el conjunto de datos de construcción del modelo. Se elige entonces el modelo múltiple lineal asociado al número de predictores que minimiza el MSE en el período de evaluación.

De manera esquemática y para representar gráficamente el comportamiento idealizado mencionado anteriormente, la Figura 4.3.5.2.1 tomada de Wilks, (2011), presenta el MSE en función del número de predictores para el período de entrenamiento y de evaluación respectivamente.




Figura 4.3.5.2.1. Esquema idealizado del MSE de la regresión en función del número de predictores para el período de entrenamiento y evaluación. Esquema tomado de Wilks, (2011).

Proposición de períodos de entrenamiento y evaluación: Validación Cruzada para predictores temporalmente dependientes

En el presente experimento utilizamos el mismo criterio de detención basado en encontrar aquellos errores que minimizan el MSE en el período de evaluación.

Para darle mayor robustez al análisis y que los resultados no dependan del subconjunto de datos escogido en la construcción de los modelos, se aplicó Validación Cruzada; metodología ampliamente implementada en estadística y cuyo objetivo consiste en estimar el nivel de ajuste de modelos construidos en distintos periodos de entrenamiento evaluándolos en distintos conjuntos de datos de prueba independientes. Este método simula la predicción de futuros datos desconocidos mediante la repetición de todo el procedimiento de ajuste en

diferentes subconjuntos de datos de entrenamiento, examinando luego las predicciones hechas para los subconjuntos de datos de evaluación restantes. Existen distintos abordajes y variantes dentro de Validación Cruzada. El más popular de ellos es conocido como “*Leave one out*”, en el cual el procedimiento de ajuste es repetido N veces, siendo la longitud del período de entrenamiento igual a N-1 datos, dejando una muestra independiente para el período de evaluación. Finalmente el MSE es calculado promediando las diferencias cuadráticas de los valores pronosticados y observados del predictando, de la muestra que no fue considerada en el procedimiento de ajuste.

Otra variante es conocida como Validación Cruzada Aleatoria para la cual los conjuntos de datos de entrenamiento y evaluación son escogidos aleatoriamente N veces, y finalmente el resultado final corresponde a la media aritmética de los valores obtenidos para los distintos subconjuntos propuestos.

Sin embargo la metodología de Validación Cruzada requiere de ciertas precauciones cuando se trata de datos que están correlacionados serialmente como en el caso de los datos de viento simulados para la región noreste patagónica. En este caso ninguno de los dos abordajes propuestos anteriormente es efectivo. Una forma de tratar esta problemática es proponer bloques continuos para el período de entrenamiento, dejando un bloque independiente suficientemente grande como período de evaluación. Este acercamiento es el que se aplicó para el conjunto de datos de esta Sección, para el cual se propusieron 4 subconjuntos de datos distintos para el período de entrenamiento y para el de evaluación. En todos los casos la longitud del período de construcción correspondía a 2/3 del registro de datos, quedando 1/3 para el período de evaluación. La Tabla 4.3.5.2.1 presenta las combinaciones formuladas en el presente trabajo.




Tabla 4.3.5.2.1. Diferentes combinaciones de períodos de construcción (verde) y evaluación (rojo).

Si se considera el abordaje clásico en el que los coeficientes son estimados en un período de entrenamiento y el modelo es evaluado en un período independiente de validación consecutivo, estamos en presencia de un caso particular de Validación Cruzada. Más información sobre esta metodología se encuentra documentada en Wilks, (2011).

En cada una de las cuatro formulaciones de los subconjuntos de entrenamiento y evaluación, se calculó el MSE de los modelos construidos con distintos número de predictores, encontrándose aquel modelo que minimiza el MSE en el período de validación. Los predictores seleccionados pueden ser diferentes para cada una de las 4 formulaciones; es por eso que el número de predictores especificado para cada plazo de pronóstico y grupo del modelo múltiple lineal formulado en la Ec. 4.3.4.1 fue basada en aquel número de predictores que

minimiza el MSE promedio de las 4 formulaciones distintas representadas en la Tabla 4.3.5.2.1, en el período de validación.

A modo de ejemplo la Figura 4.3.5.2.2 presenta el MSE en el período de entrenamiento y en el período de evaluación para los modelos construidos bajo un régimen de viento correspondiente al Grupo 9, y un plazo de pronóstico de 1 hora. En este caso los valores de MSE del período de evaluación corresponden a los valores promedios del MSE calculados para los 4 subconjuntos distintos propuestos, en donde el número de predictores que minimiza el MSE en este período es igual a 5.




Figura 4.3.5.2.2. MSE en función del número de predictores (pasos del método de Stepwise) para el período de construcción (línea negra) y evaluación (línea roja), para el modelo de pronóstico formulado en la Ec. 4.3.2.1, correspondiente al régimen 9 de viento y para un plazo de pronóstico de 1 hora.

Una vez que se determina el número final de predictores, el siguiente paso es construir el mejor modelo múltiple lineal conformado con ese número de predictores, seleccionando aquellos que explican el mayor porcentaje de la varianza observada del predictando. Nuevamente la metodología de Stepwise es implementada en la selección de estos predictores. En este caso la selección de los predictores, la estimación de sus parámetros y el cálculo de los errores asociados a este modelo se realiza utilizando el conjunto completo de datos.

4.3.6 Resultados

En este apartado se presentan los resultados obtenidos en la construcción y evaluación de los modelos múltiples lineales y la elección de los predictores asociados a éstos. Para simplificar el análisis y sin perder generalidad, se mostrarán los resultados para algunos plazos de pronóstico y grupos. Al final de la sección se resumirán los resultados obtenidos para todos los casos.

En particular se muestran los resultados para los siguientes plazos de pronóstico: 10 min, 1 hora y 3 horas y los siguientes regímenes o grupos: G1, G2 y G3.

Plazo de pronóstico: 10 min

Las Figuras 4.3.6.1-4.3.6.3 muestran la ubicación espacial de los predictores y la magnitud de los coeficientes para los grupos G1, G2 y G3, de los modelos múltiples lineales construidos para el pronóstico de viento a 10 min. En estas figuras la ubicación del punto de retícula más cercano a la posición geográfica del PER está marcada con una cruz rosa. Los cuadrados sombreados corresponden a los predictores seleccionados por la metodología de Stepwise. Los colores indican los coeficientes $a_{s,d}$ asociados a cada predictor. Aquellos coeficientes con valores cercanos a 1/-1 (colores rojos/azules) están asociados a los predictores más importantes, mientras que los coeficientes cercanos a 0 (colores verdes) se relacionan con los predictores menos importantes pero que no han sido descartados por la metodología. Dado que las series temporales de cada predictor espacial fueron desfasadas de 0 a 5 lags (0 min a 50 min), cada figura posee 6 paneles con los predictores espaciales desfasados temporalmente.

De los 10.086 potenciales predictores propuestos, la metodología de Stepwise dejó un máximo de 12 predictores en la formulación de los modelos lineales para un plazo de pronóstico de 10 min (3 predictores para G1, 12 para G2 y 8 para G3). Los predictores más importantes para G1 son las series temporales del PER en t_0 y $t_0 - 1$, siendo los coeficientes para este punto de retícula positivos y negativos respectivamente, y con valores absolutos doblemente mayores para el predictor en el tiempo t_0 respecto del valor absoluto del coeficiente en $t_0 - 1$. Se puede construir el siguiente modelo múltiple lineal aproximado para un plazo de pronóstico de 10 min y para G1, de la siguiente forma:

$$V_{s_0}(G1, k = 10min) \cong a_0(G1, k = 10min) + a_{s_0,d=1} \cdot \left(V_{s_0,d=1}(G1, t_0) - \frac{1}{2} \cdot V_{s_0,d=2}(G1, t_0 - 10min) \right) \quad \text{Ec. 4.3.6.1}$$

De esta manera el viento pronosticado está relacionado con el incremento/reducción de la velocidad registrada en el PER en las últimas mediciones, y tiene un comportamiento similar a un modelo autoregresivo de orden 2.

Los modelos de pronóstico seleccionados para un plazo de pronóstico de 10 minutos incluyen para los regímenes de viento G2 y G3, un predictor ubicado inmediatamente al sudoeste del parque eólico. Si no consideramos los restantes predictores que fueron seleccionados por la metodología y cuyos coeficientes son muy pequeños (colores verdes que indican valores cercanos a cero), se puede construir, por ejemplo, el modelo aproximado para G2

considerando que los valores absolutos de los coeficientes del predictor ubicado 14 km al sudoeste del PER en el tiempo t_0 y $t_0 - 1$ son similares. El modelo múltiple lineal está representado por la Ec. 4.3.6.2:

$$V_{s_0}(G2, k = 10min) \cong a_0(G2, k = 10min) +$$

$$a_{s_0,d=1} \cdot \left(V_{s_0,d=1}(G2, t_0) - \frac{1}{2} \cdot V_{s_0,d=2}(G2, t_0 - 10min) \right) +$$

$$a_{s_1,d=1} \cdot \left(V_{s_1,d=1}(G2, t_0) - V_{s_1,d=2}(G2, t_0 - 10min) \right) \quad \text{Ec. 4.3.6.2}$$

En este caso s_1 representa la posición geográfica del punto que se encuentra inmediatamente al sudoeste del PER. En el presente caso, el viento pronosticado está relacionado también con el incremento/reducción de la velocidad registrada a 14 km al sudoeste del parque (corriente arriba) en las últimas mediciones.

Si consideramos de segundo orden de importancia aquellos predictores selectos pero cuyos coeficientes son cercanos a cero (colores verdes), se observa en las figuras que a medida que aumenta la velocidad del viento aparecen nuevos predictores corriente arriba del PER, aunque algunos de éstos se encuentran localizados en otras regiones por fuera del área direccional delimitada en estos grupos.

La Figura 4.3.6.4 presenta la serie observada de velocidad del viento del PER y el viento pronosticado por los distintos modelos espaciotemporales (MET) propuestos para cada régimen de viento, y un plazo de pronóstico de 10 minutos. A simple vista no parecen haber diferencias apreciables entre las curvas observadas y pronosticadas por los MET. Veremos más adelante al cuantificar los errores a través del RMSE, que los errores cometidos para este plazo de pronóstico son muy pequeños para todos los regímenes de viento.

Un detalle a destacar es que los regímenes de viento son propuestos a partir de la información de dirección e intensidad del viento en el tiempo inicial de pronóstico (t_0) del PER, y es por eso que en la Figura 4.3.6.4 podemos observar valores de viento observados por fuera del rango propuesto de intensidad de viento para cada grupo, ya que no necesariamente debe cumplirse este requisito para plazos posteriores. Más aún, veremos en las figuras asociadas a plazos de pronóstico de 1 hora y 3 horas que ese efecto se presenta con mayor frecuencia y valores más alejados de los límites propuestos para cada régimen.




Figura 4.3.6.1: Predictores seleccionados para el grupo G1 y un plazo de pronóstico de 10 min. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.2: Predictores seleccionados para el grupo G2 y un plazo de pronóstico de 10 min. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.3: Predictores seleccionados para el grupo G3 y un plazo de pronóstico de 10 min. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.4: Series de viento observadas y pronosticadas por el modelo espaciotemporal propuesto (MET) para los regímenes de viento G1, G2 y G3 y un plazo de pronóstico de 10 min. En el eje x están los datos que cayeron dentro de cada grupo.

Plazo de pronóstico: 1 hora

De forma análoga a lo presentado para un plazo de pronóstico de 10 min, las Figuras 4.3.6.5-4.3.6.7 presentan los predictores selectos por Stepwise para los grupos G1, G2 y G3, y un plazo de pronóstico de 1 hora.




Figura 4.3.6.5: Predictores seleccionados para el grupo G1 y un plazo de pronóstico de 1 hora. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.6: Predictores seleccionados para el grupo G2 y un plazo de pronóstico de 1 hora. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.7: Predictores seleccionados para el grupo G3 y un plazo de pronóstico de 1 hora. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.

Complementariamente la Figura 4.3.6.8 muestra las series observadas y modeladas por los distintos MET en el período de evaluación para un plazo de pronóstico de 1 hora.




Figura 4.3.6.8: Series de viento observadas y pronosticadas por el modelo espaciotemporal propuesto (MET) para los regímenes de viento G1, G2 y G3 y un plazo de pronóstico de 1 hora. En el eje x están los datos que cayeron dentro de cada grupo.

Para G1 y G2, el método selecciona como predictores las últimas 3 observaciones de velocidad del viento como predictores principales, y algún aporte menor de otro sitio del dominio,

desfasado temporalmente. Sin embargo, para G3 el modelo de predicción es similar al descrito en la Ec. 4.3.6.2 para los pronósticos a 10 min, aunque en este caso el predictor espacial está más alejado del PER, en dirección sudoeste, consistente con la motivación planteada en la Sección 4.3.5.1, y representada gráficamente en la Figura 4.3.5.1.1.

Respecto a los vientos modelados para cada grupo y su comparación con el viento observado en el PER, se observa un muy buen desempeño de los modelos múltiples lineales construidos específicamente para cada régimen, pero con mayores diferencias respecto a lo encontrado para un plazo de pronóstico de 10 min, mayormente visible en los picos de velocidad del viento.

Plazo de pronóstico: 3 horas

Las Figuras 4.3.6.9-4.3.6.11 presentan los predictores selectos por Stepwise para los grupos G1, G2 y G3, y un plazo de pronóstico de 3 horas, mientras que la Figura 4.3.6.12 presenta los valores observados y modelados de velocidad del viento en el PER para cada grupo.

Respecto de los predictores seleccionados y en términos generales, se observa como éstos están localizados en posiciones alejadas al PER. El modelo lineal propuesto para el grupo G2 presenta un solo predictor ubicado sobre el océano al sur del PER, mientras que para los grupos G1 y G2 hay más cantidad de predictores y cuyos aportes están mejor distribuidos. Para estos grupos, los predictores más importantes se encuentran ubicados corriente arriba del PER para estos regímenes propuestos.

En la Figura 4.3.6.12 se aprecia la reducción del desempeño de estos modelos respecto de los modelos construidos para los otros plazos de pronóstico analizados previamente. Sin embargo los errores encontrados son inferiores a 1.5 m/s, medidos con el índice RMSE, siendo menor para G1 respecto de G2 y G3.




Figura 4.3.6.9: Predictores seleccionados para el grupo G1 y un plazo de pronóstico de 3 horas. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.10: Predictores seleccionados para el grupo G2 y un plazo de pronóstico de 3 horas. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.




Figura 4.3.6.11: Predictores seleccionados para el grupo G3 y un plazo de pronóstico de 3 horas. La cruz rosa indica la posición del PER. Los colores corresponden al valor de los coeficientes que acompañan a cada predictor.



Figura 4.3.6.12: Series de viento observadas en el período de evaluación y pronosticadas por el modelo espaciotemporal propuesto (MET) para cada grupo o régimen de viento y un plazo de pronóstico de 3 horas. En el eje x están los datos que cayeron dentro de cada grupo.

Desempeño de los modelos espaciotemporales para cada plazo de pronóstico y régimen de viento

La Figura 4.3.6.13 presenta el RMSE de los pronósticos de viento de los modelos espaciotemporales propuestos (línea roja), y el de un modelo de referencia a vencer como la persistencia (línea azul) para todos los plazos de pronóstico considerados, mientras que la Figura 4.3.6.14 presenta el cociente entre el RMSE de los MET respecto del RMSE de la persistencia (valores menores a 1 indican una mejora de los MET respecto del modelo de referencia).

En términos generales el RMSE de la persistencia va incrementándose a medida que aumenta el plazo de pronóstico y también al aumentar la velocidad del viento. Por ejemplo y para un plazo de pronóstico de 6 horas, el RMSE de G3 es mayor a 3 m/s, mientras que para G1 apenas supera los 2 m/s. Además este comportamiento es diferente según el Sector de dirección donde provenga el viento.




Figura 4.3.6.13: La línea roja representa RMSE del viento, de los modelos espaciotemporales propuestos para cada régimen y plazo de pronóstico y mientras que la línea azul corresponde al RMSE de un modelo de referencia (persistencia).

Los modelos espaciotemporales presentan errores menores a los del modelo de referencia para todos los plazos de pronóstico, mostrando el beneficio de utilizar la información proveniente del PER, y también aquella disponible en otras localizaciones. Si bien para los

primeros plazos de pronóstico los modelos construidos son mayormente dependientes de lo que sucede anteriormente en el mismo parque eólico, el aporte de otros predictores espacialmente distribuidos colabora en la reducción del error. Para plazos de pronóstico menores a una hora, el RMSE de los MET es aproximadamente 50% menor al del modelo de referencia, presentando incluso mayores reducciones en plazos menores a 1 hora en algunos regímenes de viento, como por ejemplo G2, G4, G5, G6, donde esta característica es más evidente.




Figura 4.3.6.14: Cociente entre RMSE de los MET y el RMSE del modelo de referencia. Valores inferiores a 1 (línea roja continua), implican un mejor desempeño de los MET respecto de la persistencia.

4.3.7 Conclusiones

En este trabajo se propusieron modelos espaciotemporales para el pronóstico de viento en el PER bajo distintos regímenes de viento y para plazos de pronóstico de 10 min a 6 horas, basados en un experimento idealizado en donde las condiciones de viento en la región noreste Patagónica fueron simuladas con el modelo WRF.

La selección de predictores fue realizada mediante la implementación de la metodología Stepwise. De los 10.086 potenciales predictores propuestos, esta metodología filtró más del 99.7% de ellos para cada modelo formulado, reservando aquellos predictores que reducen el error estimado en el período de validación a través del MSE.

Para un plazo de pronóstico de 10 min, cobran mayor importancia aquellos predictores asociados a la propia serie temporal del PER, es decir a su componente autoregresiva. A medida que aumenta la intensidad del viento, y para el mismo plazo de pronóstico, aparecen nuevos predictores corriente arriba de la ubicación del PER. El RMSE de los MET construidos para los primeros plazos de pronóstico representa alrededor del 50% de los valores asociados a un modelo simple de referencia como la persistencia, mostrando una reducción considerable del error.

A medida que se incrementa el plazo de pronóstico y la intensidad del viento, la metodología de Stepwise selecciona predictores cada vez más alejados de la posición geográfica del PER, asignándole menor importancia a la componente autoregresiva, que incluso llega a desaparecer para plazos mayores.

Como contraparte, existen algunos predictores que no fueron descartados por el método de selección, los cuales se encuentran ubicados en zonas anti-intuitivas, fuera del área delimitada por el sector al que pertenecen los distintos regímenes de viento e incluso algunos están localizados corriente abajo del PER (aunque el aporte de éstos es muy pequeño). Estos resultados son muy interesantes debido a que la metodología aplicada indica que existe una relación estadística entre lo que sucede en el PER y otros sitios, que logran explicar parte de la varianza observada de la serie temporal del parque eólico, mejorando la calidad de los pronósticos de viento. Si bien en esta sección no se intenta abordar la explicación física de esta relación, sino construir modelos espaciotemporales de pronóstico de velocidad del viento que minimicen el error para cada plazo de pronóstico involucrado, sería muy interesante en un trabajo futuro, analizar esta vinculación con un abordaje físico al problema.

Los resultados mostrados corresponden a los regímenes G1, G2 y G3, aunque similares conclusiones pueden obtenerse al explorar los predictores seleccionados para los restantes grupos.

El RMSE encontrado para todos los plazos de pronóstico varía según el sector de dirección del viento y su intensidad. Si bien el resultado no es completamente global, parece ser que bajo regímenes de viento más intenso, los errores en el pronóstico para el modelo de referencia aumentan. Esto no necesariamente ocurre de la misma manera para los MET, donde este comportamiento es menos evidente. Para todos los regímenes de viento y plazos de pronóstico, el RMSE de la intensidad del viento es menor a 2.5 m/s, valor que es alcanzado para los plazos máximos de pronóstico en el grupo G3, que coincide además con los errores más grandes hallados para el modelo de referencia.

El análisis realizado está basado en un experimento idealizado; sin embargo permite exponer el potencial beneficio de incluir información de otras estaciones meteorológicas ubicadas en la región además de la serie temporal de viento en el PER. En particular, es posible identificar potenciales ubicaciones y su aporte, que permitirían mejorar los pronósticos en el sitio de interés bajo algún régimen de viento en particular.

Los resultados obtenidos en este experimento exhiben buenos resultados, a pesar de la formulación simple que tienen estos modelos donde las relaciones propuestas entre los distintos predictores son lineales, sin haber explorado otro tipo de relación.

4.4 Pronósticos de viento y potencia a 48 hs: Método combinado

4.4.1 Introducción y antecedentes

Los modelos numéricos de previsión del tiempo (MNPT) se han implementado desde hace más de una década en el desarrollo de métodos de pronóstico de viento y potencia eléctrica generada por turbinas eólicas. Su utilización mejora el desempeño de los pronósticos de estas variables para plazos mayores a 6-10 hs respecto a aquellos basados en métodos estadísticos, que hacen uso únicamente de la última información disponible en el parque eólico en cuestión, e incluso en parques eólicos ubicados en zonas aledañas a éste.

En el trabajo de Landberg, (1994), el autor desarrolla un modelo de predicción a corto plazo, denominado Prediktor. Este método de pronóstico de potencia eléctrica utilizaba la velocidad y dirección del viento, provenientes de un MNPT, los cuales eran transformados específicamente para el sitio donde estaba instalado el parque eólico a través de un modelo sencillo de conservación de masa que parametriza cambios en el flujo local debido a la topografía, cambios en la rugosidad del terreno, y presencia de obstáculos. Finalmente las condiciones de viento local eran traducidas a potencia eléctrica utilizando la curva de potencia de los aerogeneradores involucrados, considerando el diseño espacial del parque para calcular su eficiencia. Las correcciones de los errores sistemáticos de este diseño experimental podían realizarse en cualquier momento de la cadena de acciones. Este método de pronóstico es un método físico puro, ya que no considera como predictores otra información que no se desprenda de los modelos numéricos implementados.

Siguiendo en esta misma línea relacionada con métodos puramente físicos, la Universidad de Oldenburg desarrolló en 2001 un sistema de pronóstico de potencia eólica denominado Previento. En el trabajo de Focken y otros, (2001), desarrollan un algoritmo de Upscaling para realizar pronósticos por regiones en vez de parques eólicos particulares con buenos resultados, utilizando esta herramienta. Sin embargo, tanto Prediktor como Previento poseen peores desempeños respecto de modelos puramente estadísticos para las primeras horas de pronóstico.

En la década del 90', se diseñó un modelo de pronóstico de potencia eólica denominado *Wind Power Prediction Tool* (WPPT), y cuya formulación y evaluación se presenta en el trabajo de Nielsen y otros, (2002). Este sistema de pronóstico combina óptimamente los últimos datos de potencia disponibles junto con los pronósticos de viento provenientes de MNPT a través de un modelo múltiple lineal que involucra estos predictores. Más aún, implementa cuadrados mínimos con una estimación adaptativa con olvido exponencial otorgándole mayor peso a aquellas observaciones y pronósticos cercanos a la fecha de inicialización, y menos peso a los registros más antiguos. De esa manera se consideran cambios en la configuración del MNPT involucrado, e incluso modificaciones en el entorno espacial donde se encuentra instalado el parque eólico que pueden modificar sustancialmente los parámetros que especifican los modelos propuestos. WPPT pertenece a una clase de método de pronóstico combinado, en la cual se maximizan los beneficios de la implementación de un método estadístico y uno físico. En particular WPPT ha sido implementado operativamente en Dinamarca desde 1994, y la formulación de los modelos que se propondrán en este capítulo está muy relacionada a este desarrollo.

De manera similar a WPPT, en España se desarrolla un sistema de pronóstico denominado Sipreólico. Este sistema de pronóstico estima sus parámetros a través de cuadrados mínimos de forma recurrente, y aplica filtros de Kalman, combinando de manera inteligente las últimas observaciones de potencia eólica y MNPT. Más información sobre la formulación de Sipreólico se presenta en el trabajo de Sánchez y otros, (2002).

Otros modelos propuestos complejizan las funciones de dependencia entre los últimos registros de potencia y los pronósticos de viento realizados con MNPT (Pinson y otros, 2004). Algunos de éstos involucran más de un MNPT en su formulación, otorgando distintos pesos a aquellos que poseen mejor desempeño, generando simples ensambles que mejoran el desempeño de los pronósticos medidos con el RMSE (Giebel y otros, 1999). La revisión bibliográfica presentada en el trabajo de Giebel y otros, (2011) profundiza aún más los distintos sistemas de pronóstico desarrollados alrededor del mundo, de los cuáles en esta introducción sólo destacamos los más relevantes para el desarrollo de los modelos que implementaremos en esta sección. Asimismo presenta las diferentes compañías que han surgido para cubrir las necesidades del mercado eléctrico, y que en su totalidad incluyen en el desarrollo de sus herramientas, pronósticos de viento provenientes de MNPT.

En esta sección se propondrán y evaluarán modelos de pronóstico combinados de potencia eólica para un plazo máximo de 48 horas, basados en la formulación de WPPT y Sipreólico. Estos modelos utilizan la última información disponible de viento medida en el PER y pronósticos numéricos de viento realizados con los modelos GFS y WRF. Los modelos propuestos incluyen además una dependencia direccional y fueron diseñados para ser aplicados en un contexto operativo pudiendo activar/desactivar aerogeneradores según la programación diaria de la disponibilidad de éstos. Los errores encontrados a través de índices estandarizados serán comparados con los encontrados en otras regiones del mundo, intentando identificar la fuente de las incertezas.

El trabajo está dividido de la siguiente manera: En las secciones 4.4.2 y 4.4.3 se describen los conjuntos de datos y pronósticos numéricos. La Sección 4.4.4 se presentan los modelos combinados de pronóstico de intensidad de viento, mientras que en la Sección 4.4.5 se describen las funciones de transferencia de intensidad de viento a potencia eléctrica, las cuales son función de la dirección predominante del viento. En la Sección 4.4.6 se presenta el modelo final de pronóstico de potencia eléctrica y los resultados encontrados para el caso de estudio del PER y para las distintas estaciones del año y modelos propuestos, son analizados en la Sección 4.4.7. Finalmente la Sección 4.4.8 concluye el capítulo.

4.4.2 Datos del PER

El conjunto de datos utilizado en la formulación y evaluación de los pronósticos combinados de viento y potencia eléctrica a 48 hs es idéntico a aquel descrito en la Sección 4.2.3, y en la presente sección se describirán las características más importantes de los datos utilizados.

Se contó con 2 años de datos medios horarios de velocidad y dirección de viento, y potencia eléctrica de los 43 aerogeneradores que componen el PER, con fecha de comienzo 02/04/2012. Dado que el objetivo es construir un modelo distinto de pronóstico para cada estación del año, se dividió el período completo en dos subconjuntos de datos de la misma forma que se realizó en la Sección 4.2.3. La Tabla 4.4.2.1 muestra los meses utilizados en el período de entrenamiento y evaluación para cada estación del año.

2012											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2013											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2014											
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre

Tabla 4.4.2.1. En azul están los meses utilizados en los distintos períodos de entrenamiento para cada trimestre del año (DEF, MAM, JJA y SON). En rojo los correspondientes al período de evaluación. Los meses sombreados en gris corresponden a aquellos en donde no se tienen datos.

4.4.3 Pronósticos de viento

WRF

En el Capítulo 3 se analizó el desempeño de distintas configuraciones del modelo WRF en la representación de la intensidad y dirección del viento para distintos plazos de pronóstico, para las estaciones invernal y estival. En términos generales, descartando alguna diferencia puntual existente, los resultados finales muestran que no existe una configuración en particular que produzca errores significativamente menores que las restantes para todos los casos analizados, esbozando además que la utilización de la media del ensamble de estas configuraciones proporciona mejores resultados. Dado que no existen diferencias notorias entre los valores de RMSEdb de las configuraciones de alta resolución (C1 a C4) respecto de la de baja resolución (Ctrl), y considerando además que el costo computacional es 8 veces menor para esta última configuración respecto de las restantes, se decidió realizar 2 años de pronósticos horarios a 48 horas con el modelo WRF. La configuración selecta fue entonces la denominada “Ctrl” en el Capítulo 3, y sus características completas se detallan en la Sección 3.2 de la presente Tesis. En particular la Tabla 3.2.5.1 resume sus características más importantes.

Todos los pronósticos fueron inicializados a las 12 UTC y utilizaron como condiciones iniciales y de borde los pronósticos de GFS correspondientes al mismo ciclo de pronóstico. El primer pronóstico a 48 hs fue realizado el 02/04/2012 a las 12 UTC, coincidente con los primeros registros del PER.

Se guardaron los pronósticos horarios de intensidad y dirección del viento a 10m y aprox. 92m sobre el nivel del suelo, del punto de retícula más cercano al PER para el dominio propuesto (*D-BR*), el cual posee un distanciamiento horizontal de 10 km entre puntos de retícula.

Cada punto de retícula representa las características termodinámicas y dinámicas de un área de 100 Km², mientras que el área que cubre el PER es aproximadamente 13 Km². Es de esperar entonces que el modelo sea capaz de representar las características del viento en la región cercana al PER, pero no sus variaciones locales. Por ese motivo el viento pronosticado en el punto de retícula escogido será considerado como un predictor de la velocidad media del viento medida en el PER, y no la asociada a cada uno de los aerogeneradores que componen el parque eólico.

GFS

Además de formular distintos modelos con los pronósticos regionales realizados con el modelo WRF, se compararon los resultados obtenidos con respecto al de los modelos construidos con los pronósticos de GFS. En este caso la resolución horizontal de los archivos disponibles en su dirección FTP es de 0.5°. Asimismo los archivos de pronóstico tienen una frecuencia de 3 horas, con lo cual se aplicó un método de interpolación para completar los datos faltantes y tener la misma respuesta temporal que los pronósticos de WRF. En particular se utilizó una interpolación por *splines*, proponiendo un polinomio de orden 3 para darle suavidad a la serie interpolada.

Los archivos de pronóstico del modelo GFS poseen información sobre el viento a 10m y 80m sobre el nivel del suelo, y ambas variables fueron utilizadas en la construcción de distintos modelos combinados de viento y potencia eléctrica.

4.4.4 Modelos de pronóstico de intensidad de viento

Descripción de los modelos

Se propusieron los siguientes modelos múltiples lineales combinados para predecir la velocidad media del viento en el PER, para plazos de pronóstico que van de 1 hora a 48 horas:

$$\begin{aligned}\bar{V}^{PER}(t_0 + k) = & a_1(t_0 + k) \cdot \bar{V}^{PER}(t_0) + \\ & a_2(t_0 + k) \cdot \bar{V}^{PER}(t_0 - 1) + \\ & a_3(t_0 + k) \cdot \bar{V}^{PER}(t_0 - 2) + \\ & a_4(t_0 + k) \cdot V_h^{MNPT}(t_0 + k) + \\ & a_5(t_0 + k)\end{aligned}\tag{Ec. 4.4.4.1}$$

En este caso, $\bar{V}^{PER}(t_0 + k)$ corresponde al valor pronosticado de la velocidad media del PER para un plazo de pronóstico k , inicializado en el tiempo $t_0 = 12 \text{ UTC}$. El modelo general propuesto en la Ec. 4.4.3.1 está construido como una combinación lineal de los últimos 3 promedios horarios de viento medio en el PER (primeros tres términos de la ecuación asociadas a la componente autoregresiva del viento) y los pronósticos de viento a la altura h realizados por un MNPT para el mismo plazo de pronóstico k . En esta sección V_h^{MNPT} corresponde a los pronósticos de viento horarios realizados con el modelo WRF para una altura de 10m y 92m sobre el nivel del suelo, y también a los pronósticos realizados con el modelo GFS para una altura de 10m y 80m respectivamente.

En este caso se utilizaron los valores promedios horario de viento promedio en el PER con el objeto de tener datos semejantes a la salida de los pronósticos numéricos. Además los modelos propuestos son integrales y no están enfocados solamente en el pronóstico a corto plazo (primeras 3 horas), sino que se extienden hasta las 48 horas. Este tipo de modelos está fuertemente basado en WPPT4 que incluye en su formulación los últimos valores promedios horarios de potencia, y que de forma análoga se encuentra aquí expresado para la velocidad del viento.

Para cada plazo de pronóstico se estimaron a través de cuadrados mínimos los coeficientes $a_i(t_0 + k)$ $i = 1, 2, \dots, 5$ en el período de entrenamiento y para cada estación del año. De esta manera obtenemos 4 modelos integrales de pronóstico (2 utilizan los pronósticos de WRF y otros 2 los del modelo GFS) para cada trimestre. Los coeficientes aquí encontrados se asumieron constantes en el período de evaluación, en el cual se calculan los errores de los modelos de pronóstico.

El coeficiente $a_5(t_0 + k)$ corresponde a la ordenada al origen de los modelos múltiples lineales construidos en el período de entrenamiento, y garantiza que los errores sistemáticos en este subconjunto de datos sean despreciables. Es en este término donde deberían filtrarse distintas oscilaciones como el ciclo diurno ya que son estimados para cada plazo de pronóstico.

La Figura 4.4.4.1 presenta la dependencia temporal de los 4 primeros coeficientes para los dos modelos numéricos empleados y sus alturas de pronóstico correspondientes, para el trimestre DEF. Para los primeros plazos de pronóstico, el viento medio del PER en el tiempo inicial de pronóstico es el predictor más importante, decayendo rápidamente al aumentar el plazo de pronóstico. Luego el pronóstico realizado con MNPT se convierte en el predictor más importante. Los coeficientes que acompañan a cada modelo varían en función del MNPT utilizado, y de la altura de pronóstico seleccionada. De manera análoga, la dependencia temporal de los coeficientes depende de la estación del año en la que se construyeron los modelos. La Figura 4.4.3.2 presenta esta dependencia para el modelo construido con los pronósticos de viento a 10m del modelo WRF, para cada estación del año. Este comportamiento diferencial entre estaciones del año motiva la formulación de distintos modelos que tengan en cuenta estas consideraciones.




Figura 4.4.4.1. Evolución temporal de los primeros 4 coeficientes de los modelos construidos en el período de entrenamiento para el trimestre DEF.




Figura 4.4.4.2. Evolución temporal de los primeros 4 coeficientes de los modelos construidos en el período de entrenamiento utilizando los pronósticos de viento a 10m realizados con el modelo WRF, para cada estación del año.

4.4.5 Transformación del viento a potencia: Curvas de potencia direccionales

En la Sección 4.2.6 del Capítulo 2 se propusieron 3 diferentes conjuntos de curvas de potencia. La primera de ellas es la correspondiente a la que ofrece el fabricante de los aerogeneradores Vestas V90. El segundo conjunto de curvas de potencia fueron calculadas utilizando la información de intensidad y dirección del viento y potencia eléctrica de cada aerogenerador, proponiendo 8 sectores principales de dirección de viento. Luego estas curvas de potencia individuales son sumadas obteniéndose la curva de potencia total del PER direccionalmente dependiente. La tercera aproximación corresponde al cálculo de las curvas de potencia individuales pero utilizando para ello la información del viento media del parque eólico y la potencia individual de cada aerogenerador. De esta manera se puede representar el efecto que tiene el diseño del parque eólico cuando el viento sopla de diferentes direcciones. Además permite desactivar/re-activar generadores conociendo el peso que tiene cada uno de ellos según la dirección donde provenga el viento. Esta última aproximación es la que vamos a utilizar en el presente capítulo para transformar el viento pronosticado a potencia del PER.

La Figura 4.4.5.1 muestra las curvas de potencia direccionales para tres aerogeneradores diferentes ubicados en la fila que se encuentra más al este (WT42), en el medio del parque (WT25), y en el sector sudoeste del mismo (WT1). Es fácil apreciar en esta figura el rol que cumple la dirección del viento cuando se construyen las curvas de potencia a partir de la información de viento promedio del PER. Los aerogeneradores ubicados en los extremos del parque (WT1 y WT42) presentan una mayor dispersión en la sección media de la curva de potencia (en el rango de 3 a 13 m/s), siendo sustancialmente sensibles a la dirección de donde proviene el viento. Sin embargo el aerogenerador que se encuentra en la fila intermedia del PER muestra una menor variabilidad entre las curvas direccionales. Para el WT42, cuando el viento proviene del sector Este y dado que no existe ningún obstáculo o turbina corriente arriba, la potencia es máxima respecto de otras direcciones de viento. Por el contrario, para el WT1 esto sucede cuando el viento proviene del sur.

Al sumar las curvas de potencia de los aerogeneradores para cada dirección de viento, se obtiene entonces la curva total del PER direccionalmente dependiente. La Figura 4.4.4.2 presenta en color celeste el rango de valores que adquiere la curva de potencia del PER considerando el efecto de la dirección del viento. Acompaña a estas curvas el diagrama de dispersión entre la potencia del PER en función de la velocidad media del parque eólico. La curva punteada corresponde al cálculo de la curva de potencia del PER cuando no se tiene en cuenta la dirección del viento.

Si algún aerogenerador no se encuentra en funcionamiento, se puede estimar la potencia total del PER sin tener en cuenta el respectivo aerogenerador, de manera más precisa, ya que se puede representar su aporte respecto a la potencia total siendo éste, función de la dirección de donde proviene el viento.




Figura 4.4.5.1. Curvas de potencia direccionales para tres aerogeneradores con comportamientos diferentes.




Figura 4.4.5.2. Diagrama de dispersión entre la potencia total del PER y el viento medio del parque. Las curvas de potencia direccionales están representadas en color celeste. La curva entrecortada corresponde a la curva de potencia del PER calculada sin tener en cuenta la dirección del viento.

4.4.6 Modelos de pronóstico de potencia eléctrica por regímenes de viento

En la Sección 4.4.4 se propusieron distintos modelos de pronóstico de viento combinando de forma óptima y para cada plazo de pronóstico las últimas observaciones de viento promedio en el PER y los pronósticos de viento realizados con un MNPT. Luego en la Sección 4.4.5 se propusieron curvas de potencia direccionales que permiten transformar la intensidad del viento en potencia eléctrica, conociendo la dirección de donde proviene el viento, sumando la potencia individual de cada turbina y conociendo los aerogeneradores que se encuentran en funcionamiento. Se introducen entonces los siguientes modelos de pronóstico de potencia eléctrica:

$$P_h^{MNPT}(t_0 + k, \theta_h^{MNPT}(t_0 + k)) = f(\bar{V}^{PER}(t_0 + k), \theta_h^{MNPT}(t_0 + k)) \quad \text{Ec. 4.4.6.1}$$

Donde $\bar{V}^{PER}(t_0 + k)$ es el pronóstico de viento promedio del PER para un plazo de pronóstico k calculado mediante la Ec. 4.4.4.1 y utilizando los coeficientes estimados en el período de entrenamiento. $\theta_h^{MNPT}(t_0 + k)$ corresponde al sector de viento pronosticado por el MNPT, para el plazo de pronóstico k (considerando 8 regímenes en total), y $f(\bar{V}^{PER}(t_0 + k), \theta_h^{MNPT}(t_0 + k))$ es la función de transferencia de viento a potencia realizado a partir de las curvas de potencia propuestas en la Sección 4.4.5. Finalmente $P_h^{MNPT}(t_0 + k, \theta_h^{MNPT}(t_0 + k))$ es la potencia eléctrica pronosticada para cada plazo de pronóstico, modelo numérico involucrado (WRF o GFS), y la altura de viento de los pronósticos de estos modelos (10m, 80m o 92m).

El pronóstico de viento es realizado mediante una combinación lineal de los distintos predictores involucrados. Sin embargo el pronóstico de potencia es no-lineal, ya que la transformación de viento a potencia eléctrica es realizada mediante una función que se aleja de la linealidad, y que fue propuesta en la Sección 2.6 (Ec. 2.6.1) como una combinación de funciones exponenciales.

A modo de ejemplo y para esquematizar las acciones involucradas en el pronóstico de viento y potencia eléctrica para el PER, la Figura 4.4.6.1 presenta el diagrama de flujo para el modelo que implementa los pronósticos de viento del modelo WRF a 10m sobre el nivel del suelo. El recuadro azul presenta las acciones realizadas durante el período de entrenamiento, mientras que el recuadro verde corresponde al período de evaluación.




Figura 4.4.6.1. Diagrama de flujo de las acciones realizadas en el período de entrenamiento (recuadro azul) y período de evaluación (recuadro verde).

4.4.7 Errores en los pronósticos de viento y potencia eléctrica para los modelos propuestos

Se calculó el RMSE de los pronósticos para cada plazo de pronóstico y estación del año. La Figura 4.4.7.1 muestra los valores que adquiere el RMSE de los pronósticos de intensidad del viento para los modelos combinados construidos con los pronósticos del modelo WRF y GFS para las dos alturas consideradas.

Análogamente, la Figura 4.4.7.2 presenta el RMSE de los pronósticos de potencia eléctrica normalizado por la potencia total del parque eólico (77.400 KW) de forma tal de poder comparar los valores aquí encontrados con los documentados en parques instalados en otras

regiones del mundo. De nuevo, los errores de pronóstico fueron estimados para cada estación del año y modelo propuesto.

Complementariamente se calculó otro índice de error que aparece frecuentemente en la literatura para comparar los errores en los pronósticos de potencia realizados por diferentes modelos, o en distintos parques eólicos con condiciones topográficas diferentes para plazos de pronóstico máximos del orden de días. Este índice es denominado Error Absoluto Medio (MAE, por sus siglas en inglés). Cuando se divide este índice por la potencia total del parque eólico obtenemos el Error Absoluto Medio Normalizado, o NMAE. La Figura 4.4.7.3 presenta entonces el NMAE de los pronósticos de potencia eléctrica para los distintos modelos y estaciones del año en función del plazo de pronóstico.

El cálculo del RMSE, NRMSE y NMAE fue realizado en base a 90, 92, 92 y 91 pares de pronósticos y mediciones de viento y potencia eléctrica para cada plazo de pronóstico y para los trimestres del año DEF, MAM, JJA y SON respectivamente.

La Tabla 4.4.7.1 presenta los valores medios del RMSE, NMAE y NRMSE considerando los valores de estos índices dentro del rango de plazos de pronóstico [0 hs – 48 hs], para los cuales el mayor aporte de los modelos múltiples lineales combinados proviene del término asociado al MNPT selecto. De forma análoga a lo realizado en el Capítulo 3, la Tabla 4.4.7.1 presenta el intervalo de confianza del 95% para cada uno de los índices. Los mismos fueron calculados a través de la metodología de “Bootstrap”.

	RMSE [m/s]			
	DEF	MAM	JJA	SON
WRF10	2.46 [2.39 – 2.53]	2.23 [2.17 – 2.28]	2.64 [2.58 – 2.70]	2.46 [2.38 – 2.53]
WRF92	2.48 [2.41 – 2.55]	2.20 [2.14 – 2.25]	2.64 [2.58 – 2.70]	2.42 [2.35 – 2.48]
GFS10	2.60 [2.54 – 2.68]	2.42 [2.36 – 2.47]	2.84 [2.77 – 2.91]	2.55 [2.49 – 2.62]
GFS80	2.59 [2.52 – 2.66]	2.46 [2.40 – 2.52]	2.83 [2.76 – 2.90]	2.53 [2.48 – 2.60]
	NMAE [%]			
	DEF	MAM	JJA	SON
WRF10	20.9 [20.3 – 21.5]	17.4 [16.9 – 17.9]	18.5 [18.0 – 19.0]	18.9 [18.4 – 19.4]
WRF92	21.0 [20.3 – 21.6]	17.2 [16.7 – 17.8]	18.8 [18.3 – 19.3]	18.5 [18.0 – 19.0]
GFS10	22.3 [21.6 – 22.9]	19.5 [19.0 – 20.1]	21.0 [20.4 – 21.5]	20.8 [20.3 – 21.3]
GFS80	22.2 [21.5 – 22.8]	19.6 [19.0 – 20.1]	21.3 [20.7 – 21.9]	20.6 [20.1 – 21.2]
	NRMSE [%]			
	DEF	MAM	JJA	SON
WRF10	29.7 [28.9 – 30.5]	24.6 [23.9 – 25.3]	25.9 [25.2 – 26.6]	25.8 [25.1 – 26.5]
WRF92	29.8 [28.9 – 30.6]	24.6 [23.9 – 25.2]	26.2 [25.5 – 26.8]	25.4 [24.8 – 26.0]
GFS10	30.8 [30.0 – 31.6]	27.1 [26.4 – 27.8]	28.4 [27.7 – 29.1]	27.9 [27.2 – 28.6]
GFS80	30.7 [29.9 – 31.6]	27.14 [26.7 – 28.1]	29.0 [28.3 – 29.7]	27.7 [27.1 – 28.4]

Tabla 4.4.7.1. Valores promedios de RMSE [m/s] del viento, NMAE y NRMSE [%] de la potencia eléctrica considerando el rango de plazos de pronóstico [0 hs – 48 hs]. Entre corchetes se encuentra el intervalo de confianza de 95%.

Los valores de RMSE para la velocidad del viento son similares a los hallados en el Capítulo 3, Sección 3.3 para las estaciones de verano e invierno respectivamente. Volvemos a encontrar que en el invierno los errores en el pronóstico del viento son máximos, encontrando además que el valor mínimo ocurre en el otoño. Sin embargo esto no se traslada directamente a la

potencia, debido a su función de transformación no lineal. Dado que la estación invernal está acompañada con vientos más intensos, en conjunto con una distribución de vientos con mayor frecuencia de vientos por encima de 13 m/s (velocidad nominal del aerogenerador Vestas V90), los errores en la potencia disminuyen ya que un error en el pronóstico de viento en este rango de velocidades no impacta sustantivamente en la potencia eléctrica.

Además los modelos que involucran los pronósticos de viento del modelo WRF y para este subconjunto de datos, presentan mejores desempeños que aquellos contruidos con los pronósticos del GFS como uno de sus predictores para las estaciones de otoño, invierno y primavera, siendo estas diferencias significativas. En la estación estival, si bien los rangos de los errores son menores para los modelos contruidos con el modelo WRF, estas diferencias en algunos casos no llegan a ser significativamente diferentes.

La localización y complejidad del terreno donde se encuentran instalados los parques eólicos pueden influir sustancialmente en la calidad de los pronósticos de viento y potencia eléctrica. El trabajo de Kariniotakis y otros, (2004) realiza un análisis de la calidad de los pronósticos para distintos modelos de predicción de potencia eléctrica y para 6 parques eólicos ubicados en Dinamarca, Alemania y España, en regiones costeras, mediterráneas e incluso en parques offshore. Cada uno de los parques seleccionados como casos de estudio fue descrito en su totalidad, caracterizando además la complejidad del terreno donde se encuentran emplazados a través del número de RIX (Bowen y Mortensen, 1996). Los resultados del trabajo señalan un aumento de los errores en el pronóstico a medida que la complejidad del terreno se incrementa. Para un plazo de pronóstico de 12 hs el NMAE de los parques eólicos instalados en terrenos de menor complejidad se encuentra entre 8% y 14%, incluyendo los diferentes modelos de pronóstico. Para el parque eólico Alaiz ubicado en una región con topografía muy compleja de España, el rango de valores que adquiere el NMAE se encuentra dentro de 14% y 26%, siendo en promedio cercano a 22% considerando 9 distintos modelos de pronóstico de potencia.

El valor de NMAE que presentan los modelos propuestos en esta sección de la Tesis para un plazo de pronóstico de 12 horas es de aproximadamente 19% considerando todas las estaciones del año, siendo menor en otoño respecto de las restantes estaciones. Además presenta un incremento leve en función del plazo de pronóstico. Si se comparan estos valores con los documentados en el trabajo de Kariniotakis y otros, (2002), encontramos que éstos son más elevados que aquellos encontrados por los autores para parques eólicos instalados en zonas con topografía sencilla y compleja, siendo levemente inferiores a los hallados para el parque eólico Alaiz.




Figura 4.4.7.1. RMSE del pronóstico del viento para distintos modelos y estaciones del año.




Figura 4.4.7.2. NRMSE del pronóstico de potencia eólica para distintos modelos y estaciones del año.




Figura 4.4.7.3. NMAE del pronóstico de potencia eólica para distintos modelos y estaciones del año.

Analizando el diagrama de flujo de las diferentes acciones realizadas hasta llegar al pronóstico de potencia eléctrica, los errores finales pueden provenir de tres fuentes principales:

- I. Errores en los pronósticos de los modelos combinados de velocidad del viento.
- II. Errores en los pronósticos de dirección del viento de los MNPT.
- III. Errores en la transferencia de intensidad de viento a potencia eléctrica.

Respecto a la tercera fuente de error, es posible y sencillo cuantificar su aporte. Aun realizando un pronóstico perfecto de intensidad y dirección del viento, la transferencia de viento a potencia eléctrica mediante las funciones propuestas introduce errores en las estimaciones de potencia. El error asociado a este comportamiento y medido con el índice NRMSE da como resultado 3.7%. Es decir que la definición de las curvas de potencia direccionales calculadas a partir de la información de la velocidad media del PER y los datos de potencia de cada aerogenerador, producen un error de esta magnitud. Este error representa alrededor del 14% del NRMSE total encontrado en los pronósticos de potencia eléctrica.

Supongamos ahora que tenemos un pronóstico de dirección de viento perfecto, pero no así de la intensidad del viento ni de la función de transferencia. La Figura 4.4.7.4 presenta los diagramas de dispersión entre los pronósticos de viento de los modelos construidos con los pronósticos de WRF y GFS, incluyendo todos los plazos de pronóstico entre 6 y 48 hs, y las observaciones de viento medio en el PER. Resulta evidente que los pronósticos se alejan de la perfección, pudiendo explicar menos del 48% de la varianza observada en el PER.

Se decidió entonces analizar el impacto que tiene el error en el pronóstico de viento en las predicciones de potencia eléctrica. Para ello se realizó el siguiente experimento:

1. Se perturbó la intensidad de viento promedio del PER observada agregando un error aleatorio de media igual a 0 y desvíos estándar iguales a 1, 1.5, 2, 2.5, 3 y 3.5 m/s, todos ellos menores al desvío estándar del viento promedio observado en el PER, como se mostró en el Capítulo 2. Se consideró el valor absoluto del viento de aquellos valores perturbados de viento que presenten valores negativos.
2. Se calculó el RMSE de la intensidad del viento para los vientos perturbados.
3. Los valores de viento perturbados fueron convertidos a potencia eléctrica utilizando las curvas de potencia correspondientes, según el sector de dirección de donde provenga el viento.
4. Los valores de potencia estimados fueron comparados con las observaciones de potencia medidos en el PER.
5. Se calculó el NRMSE para cada una de las series perturbadas.

La Figura 4.4.7.5 presenta los diagramas de dispersión para los vientos perturbados con un ruido aleatorio con los desvíos estándar mencionados en (1.), y el diagrama de dispersión del viento perturbado proponiendo un desvío estándar similar al encontrado para los pronósticos de viento del modelo combinado que utiliza el pronóstico de viento a 92m del WRF (3.2 m/s).




Figura 4.4.7.4. Diagramas de dispersión entre el viento pronosticado por los modelos combinados contruidos con el pronóstico de viento del modelo WRF (panel superior), y GFS (panel inferior), y el viento medio en el PER.

Los valores de RMSE de la intensidad del viento para las series perturbadas con sus respectivos desvíos estándar se presentan en la Figura 4.4.7.6. En esta figura se observa que el RMSE asociado a la serie perturbada que implementa un desvío estándar similar al que encontramos en el modelo combinado, es similar al valor que encontramos en el período de evaluación en esta misma sección (Tabla 4.4.7.1), sobrestimando levemente su valor. Esto se debe a que utilizamos como representativo un desvío estándar para todo el rango de vientos, pudiéndose refinar aún más la serie perturbada proponiendo valores de desvío estándar para distintos rangos de velocidad de viento.




Figura 4.4.7.5. Diagramas de dispersión entre el viento perturbado a través de un ruido aleatorio con los distintos desvíos estándar propuestos en i., y para el desvío estándar aproximado asociado a los pronósticos que involucran el viento a 92m del WRF.




Figura 4.4.7.6. RMSE de la intensidad del viento de las series perturbadas con diferentes desvíos estándar.

Finalmente, el impacto que tienen los errores en el pronóstico de viento respecto a las predicciones de potencia eléctrica se resume en la Figura 4.4.7.7. En esta figura podemos ver que el valor de NRMSE de la serie perturbada con el desvío estándar estimado para el modelo propuesto en la sección 4.4.4, es igual a 27%, valor que es muy similar al valor promedio de los NRMSE encontrados para cada estación del año y mismo modelo (Tabla 4.4.7.1).

Según el método de pronóstico de potencia propuesto en el presente capítulo, para alcanzar valores de NRMSE inferiores a 15%, se debería contar con un pronóstico de intensidad de viento cuyo RMSE sea inferior a 1.5 m/s. Esto, por supuesto, sin considerar el error agregado asociado al punto ii., relacionado con los errores en los pronósticos de dirección del viento, ya que modifican la forma funcional de la curva de potencia. Sin embargo su aporte es menor, siendo que i. y iii., representan prácticamente la totalidad del NRMSE encontrado para los modelos propuestos.




Figura 4.4.7.7. NRMSE de la intensidad del viento de las series perturbadas con diferentes desvíos estándar.

4.4.8 Conclusiones

En este trabajo se propusieron diferentes modelos múltiples lineales para el pronóstico de intensidad de viento en el PER y para plazos de hasta 48 hs. Estos modelos combinan de manera óptima y para cada plazo de pronóstico, las últimas observaciones de viento promedio del PER y los pronósticos de viento realizados mediante algún MNPT. En particular se formularon distintos modelos que implementan los pronósticos de viento del WRF y de GFS.

Estos modelos fueron contruidos para cada estación del año, entendiendo que el aporte de cada predictor no es sólo función del plazo de pronóstico, sino también las condiciones del flujo dominante, el cual varía según la estación del año.

En promedio para todas las estaciones del año, el RMSE de los pronósticos de intensidad media de viento en el PER es aprox. 2.5 m/s, siendo menor en otoño respecto de las restantes estaciones del año, alcanzando su máxima expresión en invierno.

Los pronósticos de intensidad de viento fueron convertidos a potencia eléctrica a través de la proposición de curvas de potencia direccionalmente dependientes. Estas funciones de transferencia no lineales fueron calculadas para cada aerogenerador utilizando el viento medio del PER y la potencia individual de cada turbina eólica. Esto fue realizado para 8 sectores de dirección principal del viento, utilizando la dirección media del PER. Finalmente la potencia total del PER es calculada sumando las potencias individuales de cada aerogenerador, conociendo la dirección de donde proviene el viento. Este enfoque permite representar las variaciones locales debidas al diseño espacial escogido en este parque eólico, y posibilita descartar el aporte de algún aerogenerador que no esté en funcionamiento de forma más precisa.

El error asociado a la transformación del viento medio del PER a potencia medido a través del índice NRMSE, es de alrededor de 3.7%. Es decir que, aun generando un pronóstico de viento perfecto, se introducen errores en la potencia de este orden.

Los errores finales encontrados para el pronóstico de potencia eléctrica resultaron similares a los hallados para parques eólicos instalados en regiones con topografía compleja/muy compleja en otras partes del mundo, siendo mayores a los encontrados para territorios con topografía simple e incluso para parques eólicos offshore.

Finalmente se buscaron las fuentes de incerteza a través de un análisis teórico que permita medir el impacto que tienen los errores en los pronósticos de dirección e intensidad de viento, como también en la conversión a potencia. El mayor aporte al error total de potencia es generado por los errores en el pronóstico de viento, tal como se suponía. Se concluye de este análisis que para el método de pronóstico propuesto, si se quiere alcanzar errores de NRMSE inferiores a 15%, es necesario que el RMSE de los pronósticos de viento sea menor a 1.5 m/s. Queda pendiente aún cuantificar el error asociado a los pronósticos de dirección del viento, que, como se mostró en el Capítulo 3, son sustanciales, particularmente cuando el viento proviene del cuadrante este.

Referencias del Capítulo 4

- Akaike, H. A new look at the statistical model identification. IEEE Transactions and automatic control. 1974. Volume 19, 716-723.
- Box, G.E.P., y Jenkins, G.M. Time Series Analysis: Forecasting and Control. Holden-Day. 1975.
- Bowen, A.J., y Mortensen, N.G. Exploring the limits of WAsP: the Wind Atlas Analysis and Application Program. Proceedings of the 1996 European Union Wind Energy Conference and Exhibition. 1996. Göteborg, Suecia. pp. 584-587.
- Brown, B.G., Katz, R.W., y Murphy, A.H. Time Series Model to Simulate and Forecast Wind Speed and Wind Power. Journal of Climate and Applied Meteorology. 1983. Volume 23, 1184-1195.
- Cadenas, E., y Rivera, W. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA e ANN model. Renewable Energy. 2010. Volume 35, 2732-2738.
- Chatfield, C. Time series forecasting. Chapman & Hall. 2000.
- Costa, A., Crespo, A., Navarro, J., Lizcano, G., Madsen, H., y Feitosa, E. A review on the young history of the wind power short-term prediction. Renewable and Sustainable Energy Reviews. 2008. Volume 12, 1725–1744.
- Damousis, I.G., Alexiadis, M.C., Theocharis, J.B., y Dokopoulos, P.S. A Fuzzy Model for Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation. IEEE: Transactions of Energy Conversion. 2004. Volume 19, N°2.
- Dowell, J., Weiss, S y Infield, D. Spatio-Temporal Prediction of Wind Speed and Direction by Continuous Directional Regime. International Conference on Probabilistic Methods Applied to Power Systems. 2014.
- Focken, U., M. Lange, H.-P. Waldl. Previento – A Wind Power Prediction System With an Innovative Upscaling Algorithm. Proceedings of the European Wind Energy Conference, Copenhagen, Denmark, 2-6 June 2001, pp. 826-829, ISBN 3-936338-09-4.
- Giebel, G., L. Landberg, K. Mönnich, H.-P. Waldl: Relative Performance of different Numerical Weather Prediction Models for Short Term Prediction of Wind Energy. Proceedings of the European Wind Energy Conference. 1999. Nice, France, pp. 1078-1081, ISBN 1 902916 00 X.
- Giebel, G, Brownsword, R, Kariniotakis, G, Denhard, M, Draxl, C, The State-Of-The-Art in Short-Term Prediction of Wind Power. 2011. ANEMOS.plus.
- Hering, A.S., y Genton, M.G. Powering Up With Space-Time Wind Forecasting. Journal of American Statistical Association. 2010. Volume 105, N° 489.
- Huang, Z., y Chalabi, Z.S. Use of time-series analysis to model and forecast wind speed. Journal of Wind Engineering and Industrial Aerodynamics. 1995. Vol 56, 311-322.

- IEC. IEC 61400-12 Wind Turbine Generator Systems – Part 12-1: Power performance measurements of electricity producing wind turbines. International Standard. 2005. Geneva - Switzerland, 1 ed., 90 p.
- Kavasseri, R.G., y Seetharaman, K. Day-ahead wind speed forecasting using f-ARIMA models. Renewable Energy. 2009. Volume 34, 1388-1393.
- Kariniotakis, G., y otros. What performance can be expected by short-term wind power prediction models depending on site characteristics?. Paper for the European Wind Energy Conference and Exhibition. 2004. Londres, Inglaterra.
- Landberg, L.: Short-term Prediction of Local Wind Conditions. PhD-Thesis, Risø-R-702(EN), Risø National Laboratory, Roskilde, Denmark 1994, ISBN 87-550-1916-1.
- Lei, M., Shiyan, L., Chuanwen, J., Hongling, L., y Yan, Z. A review on the forecasting of wind speed and generated power. Renewable and Sustainable Energy Reviews. 2009. Volume 13, 915–920.
- Milligan, M., Schwartz, M.N., y Wan, Y. Statistical Wind Power Forecasting for U.S. Wind Farms. 17th Conference on Probability and Statistics in the Atmospheric Sciences. 2004. Seattle.
- Mohandes, M.A., Halawani, T.O., Rehman, S., y Hussain, A.A. Support vector machines for wind speed prediction. Renewable Energy. 2004. Volume 29, 939-947.
- Nielsen TS, Nielsen HA and Madsen H. Prediction of wind power using time-varying coefficients functions. Proceedings of the 15th IFAC World Congress on Automatic Control. 2002. Barcelona, Spain.
- Pinson, P., Ranchin, T., y Kariniotakis, G. Short-term wind power prediction for offshore wind farms Evaluation of Fuzzy-Neural network based models. Global Wind Power Conference. 2004. Chicago, United States. pp.CD ROM, 2004.
- Pinson, P. Estimation Of The Uncertainty In Wind Power Forecasting. 2006. Tesis Doctoral. College Doctoral, Mines de París.
- Sánchez Julio Usaola, G. González, F.Soto. Sipreólico - a Wind power prediction system based on flexible combination of dynamic models. Application to the Spanish power system. 2002. Berlin, Alemania.
- Schwarz, G. Estimating the dimension of a model. Annals of statistics. 1978. Volume 6, 461-464.
- Sfetsos, A. A novel approach for the forecasting of mean hourly wind speed time series. Renewable Energy. 2002. Volume 27, 163-174.
- Snodin, H., Scott, N., y Tindal, A. Short-term wind energy forecasting: Technology and Policy. Informe Técnico Garrad-Hassan. 2006.

- Suryawanshi, A. y Ghosh, D. Wind speed prediction using spatio-temporal covariance. Natural Hazards. 2015. Volume 75, 1435-1449.
- Tastu, J., Pinson, P., Kotwa, E., Madsen, H., y Nielsen, H.Aa. Spatio-temporal analysis modeling of short-term wind power forecast errors. Wind Energy. 2010.
- Torres, J.L., García, A., De Blas, M., y De Francisco, A. Forecast of hourly average wind speed with ARMA models in Navarre (Spain). Solar Energy. 2005. Vol 70, 65-77.
- Wilks, D., S. Statistical Methods in the Atmospheric Science. Elsevier. 2011.
- Zhou, J., Shi, j., y Li, G. Fine tuning support vector machines for short-term wind speed forecasting. Energy Conversion and Management. 2011. Volume 52, 1990-1998.

Capítulo 5

Formulación de modelos de pronóstico de potencia eléctrica para nuevos parques eólicos, utilizando la información histórica y los modelos combinados contruidos para los parques eólicos existentes. Caso de Estudio: Dinamarca

Este capítulo constituye un trabajo que está en elaboración para la publicación en una revista con referato con la coautoría del Dr. Pierre Pinson

En este último capítulo se cambia la región de estudio patagónica y se llevan a cabo diversos análisis utilizando una base de datos de más de 300 parques eólicos instalados en territorio Danés. El objetivo general es la proposición y evaluación de modelos de pronóstico de potencia eléctrica basados en una versión simplificada del modelo WPPT para cada uno de estos sitios. Complementariamente se propone una generalización espacial de los coeficientes de los modelos propuestos con el objeto de estimar estos valores de forma anticipada a la instalación de nuevos parques eólicos, lo que permitiría realizar predicciones más precisas de potencia eléctrica desde el comienzo de operación de nuevos parques, hasta alcanzar un conjunto suficiente de mediciones de potencia eléctrica y pronósticos de viento que permitan calcular los coeficientes específicos de los modelos de pronóstico para estos nuevos sitios.

5.1 Introducción del capítulo

Dinamarca tiene una larga tradición y experiencia en materia de energía eólica, produciendo en la actualidad más del 30% de su energía a través de aerogeneradores. Para lograr un nivel tan alto de penetración de este tipo de energía renovable, se necesitan herramientas operativas de predicción para optimizar las operaciones de energía en los mercados y el despacho diario, entre otras cosas. La Universidad Técnica de Dinamarca (DTU) desarrolló una herramienta de predicción de potencia eólica denominada WPPT (*Wind Power Prediction Tool*), la cual se encuentra funcionando operativamente en la parte occidental de Dinamarca desde 1998, y cuya descripción completa se presenta en el trabajo de Nielsen y otros, (2002). Esta herramienta de predicción combina de forma óptima las últimas mediciones de potencia eólica disponibles, y pronósticos de viento provenientes de MNPT. Este modelo aplica además cuadrados mínimos con olvido exponencial de forma recursiva, de forma tal de representar los cambios que adquieren los coeficientes calculados para cada parque eólico otorgando más

peso a los valores más recientes de los predictores, y menos peso a los registros más antiguos. Además WPPT propone curvas de potencia paramétricas y direccionalmente dependientes que relacionan directamente los pronósticos de viento del MNPT con la potencia eólica observada. Es una herramienta versátil, utilizada operativamente en Dinamarca para hacer predicciones para parques eólicos específicos y regiones enteras.

El primer objetivo de este capítulo es la construcción y evaluación de modelos de predicción de potencia eólica simplificados basados en WPPT para más de 300 parques eólicos instalados en territorio danés, y para plazos de pronóstico máximos de 60 hs. En segundo lugar se propone una generalización espacial de estos modelos considerando a sus coeficientes como procesos estocásticos espaciales que permiten estimar sus valores en nuevos sitios a través de Kriging. La elección de esta metodología de interpolación radica en que se ha utilizado con éxito, en sus diferentes variantes, en temas relacionados con la energía eólica, sobre todo en aquellos trabajos asociados al estudio del recurso eólico, como se documenta en los trabajos de Chinta, (2014), Hur y Baldick, (2012), y Cellura y otros, (2008).

La mayor debilidad de WPPT es que requiere un historial de mediciones de potencia eólica y pronósticos de viento para estimar sus parámetros y por lo tanto no se puede aplicar con todo su potencial desde el primer momento de operación de un nuevo parque eólico. Por ello, en el segundo objetivo se plantea la posibilidad de implementar un modelo como WPPT desde el primer día de funcionamiento de un nuevo parque eólico utilizando información histórica de los modelos de pronóstico construidos en parques cercanos, hasta que un conjunto suficiente de mediciones de potencia eléctrica se haya llevado a cabo permitiendo estimar los parámetros específicos del modelo de pronóstico de potencia de ese nuevo parque con mejor precisión que la metodología de interpolación propuesta. Este enfoque es independiente del diseño específico del futuro parque eólico, que podría estar compuesto por diferentes alturas, número y tipos de turbinas eólicas. También es altamente replicable para otras regiones del mundo donde se emplean modelos similares como WPPT, con especial atención a aquellos países en los que la potencia eólica ha aumentado considerablemente en los últimos años (por ejemplo, China, Alemania y USA).

Este capítulo está estructurado de la siguiente manera: Un repaso de WPPT en su cuarta versión, los modelos simplificados construidos en base en ella y la interpolación de los coeficientes a través de Kriging Ordinario se presentan en la sección 5.2. La sección 5.3 se subdivide en 3 temas principales: la descripción del conjunto de datos para el caso de la prueba de Dinamarca en la Sección 5.3.1, la configuración experimental en la Sección 5.3.2, y el desempeño de los modelos en la Sección 5.3.3. Un resumen de los resultados más importantes y las observaciones finales terminan en la sección 5.4 del documento.

5.2 Descripción del Método

5.2.1 Repaso de WPPT

El objetivo de esta sección es relevar las características más importantes de la herramienta de predicción de potencia eólica (WPPT), un sistema versátil para la predicción de la potencia eléctrica generada por parques eólicos individuales o regiones más grandes compuestas de más de un parque eólico, que se encuentra funcionando operativamente en el oeste de Dinamarca desde 1998. Dado que en esta sección solo se revisarán algunas de sus características más importantes, es recomendable referirse al trabajo de Nielsen y otros, (2002), lo que permitirá al lector una comprensión más profunda de la formulación y los métodos aplicados en el diseño de WPPT y sus modificaciones a través del tiempo.

En su forma más general, WPPT en su cuarta versión (también conocido como WPPT4), es formulado como un modelo múltiple lineal tradicional que involucra curvas de potencia paramétricas direccionalmente dependientes, que permiten transformar los pronósticos de intensidad de viento de un MNPT en potencia eléctrica, representando además la componente no-lineal del modelo. Las ecuaciones 5.2.1.1 y 5.2.2.2 presentan la formulación general de WPPT4:

$$\hat{p}_{t+k}^{pc} = f(w_{t+k/t}^m, \theta_{t+k/t}^m, k) \quad \text{Ec. 5.2.1.1}$$

$$\begin{aligned} \hat{p}_{t+k}^{pp} = & a\left(\theta_{t+\frac{k}{t}}^m, k\right)p_t + \\ & b\left(\theta_{t+\frac{k}{t}}^m, k\right)p_{t+k}^{pc} + \\ & c^c(\theta_{t+k/t}^m, k)\cos\frac{2\pi h_{t+k}^{24}}{24} + c^s(\theta_{t+k/t}^m, k)\sin\frac{2\pi h_{t+k}^{24}}{24} \end{aligned} \quad \text{Ec. 5.2.1.2}$$

Dónde:

- p_t es la potencia observada en el tiempo t .
- $w_{t+k/t}^m$ y $\theta_{t+k/t}^m$ son la velocidad y la dirección del viento pronosticadas por un modelo numérico de pronóstico del tiempo (MNPT) para un plazo de pronóstico $t + k$.
- h_{t+k}^{24} es la hora del día para el plazo de pronóstico $t + k$.
- a, b, c^c y c^s son parámetros a estimar por cuadrados mínimos para cada plazo de pronóstico y dirección del viento.
- $\hat{p}_{t+k}^{pc}$ es el pronóstico de potencia derivado de la transformación de los pronósticos de velocidad y dirección del viento de un MNPT a través de una función de transferencia o curva de potencia cuya forma general está representada por $f()$ y que se describirá más adelante en esta misma sección.
- $\hat{p}_{t+k}^{pp}$ es el pronóstico final de potencia eléctrica resultado de una combinación lineal del último valor promedio horario de potencia eólica, los pronósticos de potencia basados en el pronóstico de intensidad y dirección del viento del MNPT

implementado, y los efectos diurnos representados por los dos últimos términos de la Ec. 5.2.1.2.

Una característica importante en los modelos de predicción de energía eólica es la definición de la función de curva de potencia $f()$. El enfoque más simple es el uso de una curva de potencia teórica que normalmente es proporcionada por los fabricantes de aerogeneradores para transferir fácilmente pronósticos de velocidad del viento en potencia, como es implementado en el trabajo de Roulston y otros, (2003). Otras estrategias involucran cuadrados mínimos, redes neuronales o métodos de agrupamiento como se propone en los trabajos de Pinson y otros, (2008), Li y otros, (2001), y Üstüntas y Sahin, (2008).

La metodología Regresión Local Pesada (o *LOESS* por sus siglas en inglés) introducida en el trabajo de Cleveland y Devlin, (1988), permite determinar una relación local entre variables sin la necesidad de proponer una función específica que cubra el rango completo de las variables independientes. Este procedimiento permite la aplicación de una función de regresión en conjunto con la estimación de sus parámetros para un número de valores fijados anticipadamente, denominados puntos de ajuste, utilizando la información que les rodea asignando pesos superiores/inferiores a aquellas muestras de las variables que se encuentren más cerca/lejos a cada punto de ajuste. Típicamente se utilizan polinomios de bajo orden o funciones sencillas y suaves para estimar la relación local en los alrededores de los puntos de ajuste.

En el diseño de WPPT, *LOESS* es utilizada para definir curvas de potencia paramétricas direccionalmente dependientes. Si se fija un sector de dirección $\theta_{t+k/t}^m$ y plazo de pronóstico k , se puede encontrar una relación entre la velocidad pronosticada del viento ($w_{t+k/t}^m$) y la potencia observada, ajustando localmente una función polinómica sobre una retícula equidistante, siendo sus nodos los puntos de ajuste, y empleando una función tri-cúbica definida por las ecuaciones 5.2.1.3 y 5.2.1.4, que permite asignar diferentes pesos a las observaciones cercanas a cada punto de ajuste.

$$\alpha_u(w_{t+k/t}^m) = W\left(\frac{\|w_{t+k/t}^m - u\|}{\beta(u)}\right) \quad \text{Ec. 5.2.1.3}$$

Dónde:

- u es un vector de los puntos de ajuste correspondiente a los pronósticos de velocidad de viento del MNPT.
- $\beta(u) > 0$ es un valor escalar denominado ancho de banda y delimita el número de observaciones que serán consideradas “cercanas” a cada punto de ajuste.
- Finalmente $\alpha_u(w_{t+k/t}^m)$ define los pesos que serán asignados a los pares de observaciones de viento y potencia, los cuáles serán función de la distancia entre ellos y cada punto de ajuste.

La función tricúbica utilizada para determinar los pesos está definida como:

$$W(x) = (1 - x^3)^3 \text{ para } 0 \leq x < 1, \text{ y } 0 \text{ fuera de ese rango} \quad \text{Ec. 5.2.1.4}$$

Luego, para los valores de viento que no pertenecen a los puntos de ajuste, los valores son estimados mediante una interpolación.

Otra característica importante implementada en WPPT es una estimación recursiva de todos los parámetros necesarios para construir el modelo. Esto es logrado a través de un algoritmo recursivo de cuadrados mínimos con olvido exponencial, permitiendo una actualización operativa de los parámetros a medida que nuevos datos de potencia y pronósticos numéricos de viento se encuentran disponibles. La razón principal de la aplicación de una estimación recursiva de los parámetros radica en que los MNPT suelen presentar cambios en sus configuraciones a lo largo del tiempo, y también los entornos aledaños a los parques eólicos suelen modificarse principalmente mediante transformaciones en la rugosidad del terreno o presencia de nuevos obstáculos. Con el objeto de poder representar estos cambios y su influencia sobre los modelos de pronóstico de potencia eólica, los diferentes parámetros son actualizados operativamente asignando mayor peso a las observaciones más nuevas, y menores a las más antiguas. Más información con respecto a la estimación recursiva y su aplicación en WPPT4 se encuentra detallada en el trabajo de Nielsen y otros, (2002).

5.2.2 Modelo simplificado basado en WPPT4

A partir de la formulación completa de WPPT4, se construyeron modelos de pronóstico de potencia eólica simplificados de la siguiente manera:

$$\hat{p}_{t+k}^{pc} = f(w_{t+k/t}^m, k) \quad \text{Ec. 5.2.2.1}$$

$$\hat{p}_{t+k}^{pp} = a(k)p_t + b(k)p_{t+k}^{pc} + c(k) \quad \text{Ec. 5.2.2.2}$$

Ahora $a(k)$, $b(k)$ y $c(k)$ son los parámetros a estimar por cuadrados mínimos para cada plazo de pronóstico k , y el resto de las variables siguen siendo las mismas que han sido descritas en la Sección 5.2.1.

Dos diferencias importantes con respecto a la formulación WPPT4 se pueden identificar rápidamente en las Ec. 5.2.2.1 y 5.2.2.2. En primer lugar se descarta la representación explícita del ciclo diurno sustituyendo estos términos por uno correspondiente a la ordenada al origen $c(k)$, cuyo valor es función del plazo de pronóstico k . En segundo lugar, en la evaluación de dos versiones diferentes de WPPT (Nielsen y otros, 2002), los autores probaron que la inclusión de coeficientes y curvas de potencia paramétricas dependientes de la dirección del viento produjo un mejor desempeño en los pronósticos de potencia eólica para los 6 parques eólicos considerados en el estudio. Sin embargo esta mejora es considerable sólo para uno de los cinco parques eólicos daneses analizados (el sexto fue el parque eólico La Muela, situado en España). Por lo tanto, la segunda modificación en la formulación del modelo es la decisión de no tener en cuenta la dependencia de la dirección del viento en las curvas de potencia y los distintos parámetros a estimar por cuadrados mínimos para cada plazo de pronóstico, teniendo en cuenta que esta simplificación sólo introduciría pequeños errores para nuestros propósitos.

Por último, no se aplicó una estimación recursiva de los parámetros del modelo ya que no es objeto del presente capítulo la aplicación operativa de las metodologías propuestas. En cambio se decidió dividir el conjunto total de datos en dos subconjuntos: un “período de entrenamiento” en el cual los distintos parámetros del modelo son estimados, y un “período de evaluación” donde se calculan distintas medidas de error, según se recomienda en el trabajo de Madsen y otros, (2005).

5.2.3 Generalización espacial de los modelos: Características principales de Kriging Ordinario

Kriging (Krige, 1966) es una metodología de interpolación espacial ampliamente utilizada en ciencias de la tierra que permite estimar el valor de una variable en una posición geográfica distinta a aquellas donde se han tomado mediciones de la variable de interés, proporcionando además una medida de la incertidumbre de la estimación. Esta metodología utiliza la información obtenida del semivariograma, una figura análoga al correlograma donde la semivarianza (Ec. 5.2.3.1) es graficada en función de la distancia, describiendo el grado de dependencia espacial de un proceso estocástico. A partir del semivariograma es posible asignar un conjunto óptimo de pesos a las observaciones para la estimación de la variable deseada en una nueva posición desconocida.

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(s_i) - Z(s_i + h)]^2 \quad \text{Ec. 5.2.3.1}$$

Aquí $Z(s_i)$ es la variable regional (que se considera tiene características intermedias entre una variable aleatoria y una determinística) medida en una posición geográfica determinada s_i ; h corresponde a la distancia euclídea entre datos ordenados, y $N(h)$ es el número de pares de datos en una distancia h .

El valor en una ubicación sin muestrear se estima entonces como una combinación lineal pesada de los valores observados en los puntos de medición circundantes de la siguiente manera:

$$\hat{Z}(s) - m(s) = \sum_{i=1}^{n(s)} \lambda_i [Z(s_i) - m(s_i)] \quad \text{Ec. 5.2.3.2}$$

Siendo $n(s)$ el número de estaciones utilizadas en la estimación de la variable regional $\hat{Z}(s)$ en una nueva posición geográfica. s y s_i son vectores que indican las posiciones geográficas de las nuevas ubicaciones donde se estimarán los valores de la variable Z y las posiciones geográficas donde existen observaciones de esta misma variable. $m(s)$ y $m(s_i)$ son los valores esperados de $Z(s)$ and $Z(s_i)$, y finalmente λ_i son los pesos asignados por la metodología de Kriging a cada ubicación s_i .

Los pesos λ_i son escogidos de forma tal de que la estimación no tenga errores sistemáticos y que a su vez presente varianza mínima. Cuando no existe tendencia, es decir: $m(s) = m(s_i) = m$, se está en presencia de “Kriging Simple”. En cambio, si el proceso es estacionario asumiendo que el valor esperado es constante solamente en el entorno local del punto de estimación, entonces la metodología es denominada “Kriging Ordinario” (KO). Esta suposición conduce a una condición adicional que requiere que la suma de los pesos asignados Kriging sea igual a 1.

$$\sum_{i=1}^{n(s)} \lambda_i = 1 \quad \text{Ec. 5.2.3.3}$$

Con esta consideración la ecuación 5.2.3.2 resulta en:

$$\hat{Z}(s) = \sum_{i=1}^{n(s)} \lambda_i Z(s_i) \quad \text{Ec. 5.2.3.4}$$

Finalmente, para encontrar los pesos λ_i el siguiente sistema de ecuaciones debe ser resuelto:

$$\begin{array}{ccccccccc} \lambda_1 \gamma(h_{11}) & + & \lambda_2 \gamma(h_{12}) & + & \cdots & + & \lambda_n \gamma(h_{1n}) & + & \delta & = & \gamma(h_{1p}) \\ \lambda_1 \gamma(h_{21}) & + & \lambda_2 \gamma(h_{22}) & + & \cdots & + & \lambda_n \gamma(h_{2n}) & + & \delta & = & \gamma(h_{2p}) \\ \vdots & + & \vdots & + & \vdots & + & \vdots & + & \vdots & = & \vdots \\ \lambda_1 \gamma(h_{n1}) & + & \lambda_2 \gamma(h_{n2}) & + & \cdots & + & \lambda_n \gamma(h_{nn}) & + & \delta & = & \gamma(h_{np}) \\ \lambda_1 & + & \lambda_2 & + & \cdots & + & \lambda_n & + & 0 & = & 1 \end{array} \quad \text{Ec. 5.2.3.5}$$

En este caso p corresponde a la ubicación geográfica del sitio de interés donde se quiere estimar el valor de la variable regional Z , δ es un multiplicador de Lagrange propuesto para agregar un grado de libertad extra, asegurando que la solución del sistema de ecuaciones presente el error mínimo posible, y $\gamma(h_{ij})$ es la semivarianza sobre una distancia h entre los pares de puntos i y j . Estos valores se toman del semivariograma que debe ser estimado antes de resolver este sistema de ecuaciones.

En particular y para el caso de estudio de Dinamarca, se considerará a los coeficientes $a(k)$, $b(k)$ y $c(k)$ de los modelos simplificados de pronóstico de potencia eólica (Ec. 5.2.2.2) como variables regionales, permitiendo estimar sus valores en otros sitios utilizando para ellos la metodología de Kriging Ordinario.

5.3 Implementación para el caso de estudio de Dinamarca

5.3.1 Datos

Los datos de potencia eólica fueron proporcionados por ENERGINET, compañía operadora de la red eléctrica y transporte de gas natural de Dinamarca. El conjunto de datos está compuesto por 3 años completos (2008 a 2010) de observaciones de potencia eólica en 314 subestaciones eléctricas diferentes, todas ellas ubicadas en la región continental de Dinamarca. Vale mencionar que existen más subestaciones dentro del conjunto de datos. Sin embargo, y luego de un proceso de verificación de la calidad de los mismos, se decidió focalizar el estudio utilizando aquellos sitios en los que la calidad de los datos fue casi perfecta. La distribución geográfica de las subestaciones eléctricas finales se muestra en la Figura 5.3.1.1.

Cada subestación eléctrica proporciona información de potencia eólica del conjunto de aerogeneradores que se encuentran conectados a ella. A su vez cada una de estas subestaciones puede tener conectado un número diferente de turbinas, como así también estar compuesta por aerogeneradores de distinto tipo y alturas. La resolución temporal de los datos suministrados es de 15 minutos, aunque se consideraron las series promediadas en una

ventana horaria de forma tal de ser coherentes con los campos de viento provistos por el MNPT utilizado. Cada serie temporal fue normalizada dividiendo sus registros por su potencia máxima, de forma tal que la serie final adopta valores adimensionales entre 0 y 1, representando el porcentaje de generación de potencia. De ahora en adelante y dentro del contexto de este trabajo, adoptaremos la denominación “parque eólico” como sinónimo de subestación eléctrica.




Figura 5.3.1.1. Distribución geográfica de las 314 subestaciones consideradas en el presente estudio, todas ellas ubicadas sobre la porción continental de Dinamarca.

Respecto a los pronósticos numéricos de viento, el Instituto Meteorológico de Dinamarca (DMI) proporcionó pronósticos horarios de velocidad del viento a 10m y 100 metros sobre el nivel del suelo, hasta 60 horas, correspondientes al mismo período que los datos de potencia. Los pronósticos fueron realizados con el modelo regional Hi Resolution Limited Area Model (HIRLAM), con un espaciamiento entre puntos de retícula de 0.15°, e inicializados 4 veces por día (00, 06, 12 y 18 UTC). Por simplicidad el análisis hecho en este capítulo se focalizó en el ciclo de pronóstico de las 12 UTC, y se seleccionó el punto de retícula del modelo más cercano a cada parque eólico como predictor. Una breve descripción de la configuración del modelo y las modificaciones que se han aplicado al nuevo modelo DMI-HIRLAM operativo es presentado en el informe técnico de Petersen y otros, (2005).

5.3.2 Diseño del experimento

Como se mencionó en la Sección 5.2.2, el modelo de pronóstico propuesto para cada parque eólico en la porción continental de Dinamarca está descrito por las ecuaciones 5.2.2.1 y 5.2.2.2, pero se aplicaron las siguientes modificaciones en la definición de la curva de potencia:

i. En vez de construir una curva de potencia para cada parque eólico y plazo de pronóstico, se construyó una curva de potencia media válida para toda la región utilizando los pares de datos de potencia eólica y pronósticos de velocidad a 10m del modelo DMI-HIRLAM, de los 314 parques eólicos, para cada plazo de pronóstico

ii. La estimación de la curva de potencia se hizo a través de LOESS, pero en lugar de la función tri-cúbica propuesta para asignar los pesos (Ec. 5.2.1.4), se decidió implementar un núcleo gaussiano con un ancho de banda fijo, de forma tal de que el rango fuera continuo.

Los primeros 2 años de datos se utilizaron para estimar la curva de potencia y los coeficientes $a(k)$, $b(k)$ y $c(k)$ de los modelos simplificados de pronóstico de potencia para cada parque eólico y plazo de pronóstico. Luego, asumiendo que estos coeficientes y curvas de potencia no presentan cambios significativos en el período de evaluación, fueron utilizados para la generación de pronósticos en este período, calculando distintas medidas de error para analizar el desempeño de estos modelos.

Respecto al segundo objetivo asociado a la generalización espacial de estos modelos y teniendo en cuenta que la metodología de interpolación es sensible a la distribución geográfica de los parques eólicos en la estimación de la variable de interés para una nueva ubicación, se propuso el siguiente diseño experimental con el fin de evaluar los errores que induce la interpolación espacial de los coeficientes $a(k)$, $b(k)$ y $c(k)$ en los pronósticos de potencia:

Paso 1: Selección **aleatoria** de 214 parques eólicos.

Paso 2: Los coeficientes $a(k)$, $b(k)$ y $c(k)$ de los modelos de pronóstico de los 214 parques eólicos seleccionados en el primer paso, son interpolados a las posiciones geográficas de los restantes 100 parques eólicos y para cada plazo de pronóstico a través de Kriging Ordinario.

Paso 3: Debido a que los resultados de la metodología de interpolación pueden ser sensibles a la distribución geográfica de los 214 parques seleccionados en el paso 1, los pasos 1 y 2 se repitieron $N = 300$ veces. Al final de este proceso cada parque eólico fue seleccionado para estimar los valores de los coeficientes $a(k)$, $b(k)$ y $c(k)$ en sus respectivas ubicaciones geográficas, entre 75 y 115 veces.

Paso 4: Se consideraron los valores medios de los coeficientes interpolados para cada parque eólico y plazo de pronóstico.

Como resultado de este diseño experimental el siguiente modelo de pronóstico de potencia eólica se construyó para cada parque eólico:

$$\hat{p}_{t+k}^{OK} = \bar{a}_{ok}(k)p_t + \bar{b}_{ok}(k)p_{t+k}^{pc} + \bar{c}_{ok}(k) \quad \text{Ec. 5.3.2.1}$$

Dónde $\bar{a}_{ok}(k)$, $\bar{b}_{ok}(k)$ y $\bar{c}_{ok}(k)$ son los coeficientes interpolados promedio para cada plazo de pronóstico k .

5.3.3 Resultados

En primer lugar, el desempeño de los modelos simplificados de pronóstico de potencia eólica descritos en la Sección 5.2.2 con los ajustes propuestos en la Sección 5.3.2 es analizado para el caso de estudio de Dinamarca.

La Figura 5.3.3.1 presenta el desempeño de estos modelos, medido a través del índice de error NMAE y NRMSE, para los 314 parques eólicos, y para cada plazo de pronóstico. Esta figura muestra en sombreado los deciles de la distribución de cada índice de error, mientras que la línea continua color rojo representa el valor medio.

Los valores de NMAE aumentan rápidamente en las primeras 3 horas de pronóstico, presentando un fuerte ciclo diurno donde los valores más altos ocurren durante las horas diurnas, y los más bajos durante el período nocturno, teniendo en cuenta que los pronósticos son inicializados a las 12 UTC, hora correspondiente a aproximadamente el mediodía en la hora local de Dinamarca.

La Tabla 5.3.3.1 resume el valor medio de los índices NMAE y NRMSE, y del coeficiente de determinación (R^2) para diferentes plazos de pronóstico. Este último índice cuantifica el porcentaje de la varianza de las observaciones de potencia eólica explicada por el modelo de pronóstico utilizado, adquiriendo valores de 1 para un modelo perfecto y 0 cuando el modelo no explica varianza alguna.

	+1 hr	+12 hr	+24 hr	+36 hr	+48 hr	+60 hr
NMAE	5.4%	9.1%	12.5%	10.5%	15.8%	12.2%
NRMSE	8.2%	13.0%	16.7%	14.9%	20.6%	17.2%
R^2	0.91	0.70	0.65	0.59	0.51	0.46

Tabla 5.3.3.1. Valores promedio de NMAE, NRMSE y R^2 para algunos plazos de pronóstico.

Los valores de NMAE aquí estimados son similares a los documentados para parques eólicos instalados en regiones con topografía simple, como se menciona en el trabajo de Kariniotakis y otros, (2004), mientras que los valores de R^2 son, en términos medios, ligeramente superiores a los documentados en el trabajo de Nielsen y otros, (2002), para el modelo WPPT4. Este mejor desempeño podría explicarse por las continuas modificaciones que han sido implementadas en los modelos numéricos de predicción del tiempo en las últimas décadas, mejorando los pronósticos de velocidad del viento en niveles bajos de la atmósfera.

Si comparamos los valores aquí encontrados respecto de los documentados en la Sección 4.4.7 para el Parque Eólico Rawson, se observa que en términos medios los errores en el pronóstico medidos a través del índice NMAE y NRMSE son aproximadamente un 39% menores considerando los plazos de pronóstico entre 6 y 48 hs.

La distribución espacial del NMAE para 4 plazos de pronóstico es presentada a través de los cuartiles de su distribución en la Figura 5.3.3.2. Si bien en términos medios los valores de NMAE son menores en horas nocturnas (plazos de pronóstico de 12 horas y 36 horas), hay una mayor variabilidad de estos valores respecto de los pronósticos hechos para horas diurnas. Existen regiones como la sección noroeste de la porción continental de Dinamarca donde los errores se mantienen en los primeros cuartiles para los diferentes plazos de pronóstico mostrados, y otros sectores como la porción norte donde los valores de NMAE pertenecen mayoritariamente al tercer y cuarto cuartil para todos los plazos de pronóstico. Asimismo la región sur y una pequeña sección ubicada en la porción central Este presentan características alternantes entre las horas diurnas y nocturnas. La sección sur presenta errores más bajos en horas diurnas respecto a las nocturnas, mientras que la región Este central muestra un comportamiento opuesto.




Figura 5.3.3.1. NMAE y NRMSE en función del plazo de pronóstico. El sombreado azul representa los deciles de la distribución de cada índice considerando los 314 parques eólicos utilizados en este estudio, y la línea roja continua representa su valor medio.




Figura 5.3.3.2. Distribución espacial de los cuartiles de NMAE para 4 diferentes plazos de pronóstico.

Dado que los modelos de pronóstico simplificados se construyen como una combinación lineal entre un término asociado a la componente autoregresiva de la potencia eólica, un pronóstico de potencia basado en los pronósticos de velocidad de viento del modelo DMI-HIRLAM y un término constante, es útil analizar los pesos asignados a cada componente para cada plazo de pronóstico y parque eólico. La Figura 5.3.3.3 muestra los deciles de la distribución de los coeficientes $a(k)$, $b(k)$ y $c(k)$ en sombreado y su valor medio en líneas de trazos en función del plazo de pronóstico.

El término asociado a la componente autoregresiva domina en las dos primeras horas de pronóstico con muy poca variabilidad entre parques eólicos, disminuyendo muy rápido y alcanzando un valor cercano a cero para un plazo de pronóstico de 7 horas. A partir de la tercera hora de pronóstico hay un predominio marcado del término asociado al modelo de predicción numérica del tiempo, mientras que el coeficiente $b(k)$ muestra una gran dispersión entre parques eólicos. Dada esta dispersión de este coeficiente entre parques, es posible implementar Kriging Ordinario como un método interesante para modelar la variabilidad espacial de los modelos de pronóstico.




Figura 5.3.3.3. Coeficientes $a(k)$, $b(k)$ y $c(k)$ en función del plazo de pronóstico. En sombreado se presentan los deciles de la distribución de cada coeficiente considerando 314 parques eólicos, y en líneas discontinuas negras su valor medio.

Respecto al segundo objetivo asociado a la generalización espacial de los modelos de pronóstico, se propuso un modelo de referencia simple a vencer denominado “*First Guess*” (por su denominación en inglés), construido con los valores promedios de los coeficientes $a(k)$, $b(k)$ y $c(k)$ estimados para cada parque eólico. La formulación de este modelo para cada parque y plazo de pronóstico se presenta en la Ec. 5.3.3.2.

$$\hat{p}_{t+k}^{BM} = \bar{a}_{BM}(k)p_t + \bar{b}_{BM}(k)p_{t+k}^{pc} + \bar{c}_{BM}(k) \quad \text{Ec. 5.3.3.2}$$

Dónde $\bar{a}_{BM}(k)$, $\bar{b}_{BM}(k)$ y $\bar{c}_{BM}(k)$ son los coeficientes promedio calculados a partir de los coeficientes $a(k)$, $b(k)$ y $c(k)$ específicos estimados para cada parque eólico y plazo de pronóstico en el período de entrenamiento.

Complementariamente se construyeron modelos como los propuestos en la Sección 5.2.2, pero la estimación de sus parámetros se realizó utilizando diferentes longitudes temporales del período de entrenamiento, desde dos semanas en adelante. De esta manera se puede calcular la cantidad de semanas mínimas de mediciones de potencia eólica y pronósticos numéricos de viento, necesarias para estimar los coeficientes específicos de ese nuevo parque,

para introducir los mismos niveles de error que los modelos de referencia (*First Guess*) y aquellos construidos con los coeficientes interpolados a través de Kriging Ordinario.

La Figura 5.3.3.4 presenta la adición al error que generan los modelos de referencia (*First Guess*), los asociados a la metodología de interpolación de Kriging Ordinario, y aquellos construidos con diferentes longitudes temporales del período de entrenamiento, respecto de los valores de NMAE estimados por los modelos descritos en la Sección 5.2.2. Las curvas presentadas en esta figura corresponden a los valores promedio calculados a partir de los errores de los 314 parques eólicos y todos los plazos de pronóstico involucrados.




Figura 5.3.3.4. adición al error que generan los modelos de referencia (*First Guess*), los asociados a la metodología de interpolación de Kriging Ordinario, y aquellos construidos con diferentes longitudes temporales del período de entrenamiento, respecto de los valores de NMAE estimados por los modelos simplificados descritos en la Sección 5.2.2.

Se necesitan entre 14 y 22 semanas de mediciones de datos para lograr la misma adición en el NMAE que los modelos denominados *First Guess*, y aquellos construidos mediante la interpolación por Kriging respectivamente. Además los errores introducidos por los modelos *First Guess*, duplican los valores encontrados para los modelos con coeficientes espacialmente interpolados.

Complementariamente la Figura 5.3.3.5 presenta la adición media en el NMAE en función del plazo de pronóstico para los mismos modelos involucrados en la figura anterior. En particular las curvas discontinuas presentan la adición al NMAE de los modelos que estiman los coeficientes en un período de entrenamiento de 10 y 20 semanas de longitud.

Se observa una mayor adición de error en las horas nocturnas (aprox. +12hs, +36hs y +60hs) para los modelos de referencia y los interpolados (curvas rojas y azules), coincidentes con los momentos donde el coeficiente $b(k)$ adquiere su máxima dispersión entre parques eólicos (Figura 5.3.3.3).




Figura 5.3.3.5. Adición media en el NMAE en función del plazo de pronóstico para los mismos modelos involucrados en la figura anterior.

Con el fin de hacer un análisis espacial del desempeño de los modelos con los coeficientes interpolados a través de Kriging Ordinario, la Figura 5.3.3.6 presenta el número de semanas de observaciones necesarias para construir los modelos simplificados descritos en la Sección 5.2.2, con el fin de adquirir el mismo nivel de errores que estos modelos. Esta figura muestra que aproximadamente el 66% de los parques eólicos necesitan más de 22 semanas de mediciones para obtener el mismo nivel de precisión. Sin embargo hay un gran número de parques eólicos, principalmente ubicados cerca de la costa, donde rápidamente este número disminuye a valores incluso menores a 10 semanas. Mayormente los parques eólicos que requieren menos de 22 semanas se encuentran localizados en zonas costeras, mientras que la mayoría de los parques que requieren más de 22 semanas se encuentran principalmente instalados tierra dentro.

Existen también algunos parques eólicos denotados por puntos negros donde los modelos con coeficientes interpolados se desempeñan levemente mejor que los modelos contruidos con 2 años de datos. Este efecto puede ser puramente aleatorio, pudiendo estar asociado a la sobrestimación de los parámetros, dado que estos parques eólicos se encuentran principalmente ubicados en zonas con mayor densidad de subestaciones.




Figura 5.3.3.6. Número de semanas del periodo de entrenamiento necesarias para lograr la misma precisión que los modelos con coeficientes interpolados.

5.3.4 Discusión y conclusiones

En el presente capítulo se construyeron y evaluaron modelos de pronóstico de potencia eólica simplificados basados en la formulación de WPPT4, para el caso de estudio de Dinamarca, utilizando uno de los conjuntos de datos de potencia eólica más completos de todo el mundo. Estos modelos combinan las observaciones de potencia eólica y los pronósticos de viento a 10m provenientes de un MNPT, que luego son transformados a potencia eléctrica a través de una curva de potencia definida para toda la porción continental de Dinamarca, para cada plazo de pronóstico.

Los valores de NMAE calculados en este trabajo son similares a los documentados para parques eólicos contruidos sobre terrenos de topografía sencilla, y presentan un fuerte ciclo

diurno donde los errores más grandes ocurren durante las horas diurnas, mientras que lo opuesto ocurre en horas nocturnas. Este comportamiento puede deberse a las dificultades en la representación de la variabilidad de la velocidad del viento de 10 metros por el modelo de predicción numérica del tiempo, principalmente relacionados con una peor representación de los efectos de capa límite durante el día.

Dada la disponibilidad de los pronósticos de viento a 100m sobre el nivel del suelo, se construyeron modelos de pronóstico de potencia eólica simplificados utilizando los vientos pronosticados a esta altura como uno de sus predictores y se compararon los resultados para estos modelos con los obtenidos a lo largo del capítulo que hacían uso de los pronósticos de viento a 10m. La Figura 5.4.1 presenta en sombreado azul los deciles de la distribución de las diferencias de NMAE en función del plazo de pronóstico, considerando los 314 parques eólicos. La línea roja continua representa el valor medio de estas diferencias.




Figura 5.4.1. En sombreado azul, los deciles de las diferencias de NMAE entre los modelos formulados con los pronósticos de viento a 100m, respecto de aquellos construidos con los pronósticos a 10m sobre el nivel del suelo. La línea roja continua representa el valor medio de estas diferencias.

Resulta evidente en esta figura la ventaja de utilizar los pronósticos de velocidad del viento a 10m para casi todos los parques eólicos y plazos de pronóstico considerados en este estudio. La utilización de los pronósticos a 100m como predictor en los modelos finales de predicción de potencia eólica introducen en términos medios, errores mayores a 1% considerando todos los plazos de pronóstico a excepción de las primeras horas donde la componente autoregresiva domina los modelos de pronóstico de potencia, y a aquellas horas cercanas a la puesta del sol.

Sería interesante contar con un conjunto de datos meteorológicos observados dentro del mismo período para analizar las capacidades del modelo DMI-HIRLAM en representar la variabilidad de la velocidad del viento a diferentes alturas dentro de la capa límite, para diferentes regímenes de estabilidad así como diferentes configuraciones de este modelo, para poder completar esta discusión con una atribución de errores, pero los mismos no estaban disponibles.

Adicionalmente en este capítulo se propuso y evaluó una metodología de interpolación para la estimación de los parámetros de los modelos de pronóstico a nuevas ubicaciones utilizando la información de los parques eólicos aledaños a esta localización. En particular se seleccionó la metodología de Kriging Ordinario para conseguir este objetivo.

En términos medios, los errores introducidos por los modelos construidos utilizando los coeficientes estimados por esta metodología introducen pequeños errores y se desempeñan alrededor de un 100% mejor respecto de un modelo de referencia simple que utiliza los coeficientes promedios de los 314 parques. Es interesante notar que la magnitud del NMAE introducida por los modelos con los coeficientes interpolados es alrededor de 3 veces más pequeña que los errores introducidos por aquellos modelos construidos con los pronósticos de viento a 100m sobre el nivel del suelo.

Por último, se realizó una comparación entre los modelos construidos con los coeficientes interpolados y los construidos utilizando diferentes longitudes temporales del período de entrenamiento. En términos medios se necesitan por lo menos 22 semanas de mediciones de potencia eólica y pronósticos numéricos de velocidad del viento para estimar los parámetros de los modelos con el fin de tener el mismo nivel de precisión que los modelos interpolados para aproximadamente el 66% de los parques eólicos instalados en la región continental de Dinamarca.

Estos resultados sugieren que es posible poner en práctica con resultados prometedores, un modelo de pronóstico de potencia eólica como WPPT desde el principio de funcionamiento de un nuevo parque eólico, independientemente de su tamaño, diseño y tipo de turbinas de viento que lo componen, utilizando los parámetros espacialmente estimados a través de Kriging Ordinario, hasta que un conjunto suficiente de datos de potencia eólica sea medido y puedan calcularse los coeficientes específicos para ese nuevo sitio.

Referencias del Capítulo 5

- Cellura M, Cirrincione G, Marvuglia A, and Miraoui A. Wind speed spatial estimation for energy planning in Sicily; A neural kriging application. *Renewable Energy*. 2008. 3:1251-1266.
- Chinta S. A comparison of spatial interpolation methods in wind speed estimation across Anantapur District, Andhra Pradesh. *Journal of Earth Science Research*. 2014. 2:48-54.
- Cleveland WS and Devlin SJ. Locally Weighted Regression: An Approach to Regression Analysis by Local Fitting. *Journal of the American Statistical Association*. 1988. 83:596-610.
- Hur J and Baldick R. Spatial Prediction of Wind Farm Outputs Using the Augmented Kriging-Based Model. *Power and energy Society General Meeting*. 2012. San Diego, USA.
- Krige DG. Two-dimensional weighted moving average trend surface for ore-evaluation. *Journal of the South African Institute of Mining and Metallurgy*. 1966. 66:13-38.
- Kariniotakis G, Martí I, Pinson P, Nielsen TS, Madsen H, Giebel G, et al. What performance can be expected by short-term wind power prediction models depending on site characteristics?. *EWEC*, 2004. Londres, Inglaterra.
- Li S, Wunsch D and O'Hair E. Comparative Analysis of Regression and Artificial Neural Network Models for Wind Turbine Power Curve Estimation. *Journal of Solar and Energy Engineering*. 2001. 123:327-332.
- Madsen H, Pinson P, Kariniotakis G, Nielsen HA and Nielsen TS. Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models. *Wind Engineering*. 2005. 29:475-489.
- Nielsen TS, Nielsen HA and Madsen H. Prediction of wind power using time-varying coefficients functions. *Proceedings of the 15'th IFAC World Congress on Automatic Control*. 2002. Barcelona, España.
- Petersen C, Kmit M, Nielsen W, Amstrup B and Huess V. Performance of DMI-HIRLAM-T15 and DMI-HIRLAM-s05 and the storm surge model in winter storms. *Danish Meteorological Institute*. 2005. Technical Report 05-13.
- Pinson P, Nielsen HA, Madsen H, and Nielsen TS. Local Linear Regression With Adaptive Orthogonal Fitting for the Wind Power Application. *Statistics and Computing*. 2008. 18:59-71.
- Roulston MS, Kaplan DT, Hardenberg J and Smith LA. Using medium-range weather forecasts to improve the value of wind energy production. *Renewable Energy*. 2003. 28:585-602.
- Üstüntas T and Sahin AD. Wind turbine power curve estimation based on cluster center fuzzy logic modelling. *Journal of Wind Engineering and Industrial Aerodynamics*. 2008. 96:611-620.

Capítulo 6

Conclusiones generales

La energía eólica ha crecido exponencialmente en las últimas décadas a escala global, enmarcado en un contexto donde los avances tecnológicos y científicos han permitido que este tipo de energías renovables adquiera mayor competitividad dentro del mercado eléctrico dominado mayormente por otro tipo de fuentes de generación de energía.

Dentro del contexto nacional actual, nuevas políticas se propusieron con el objeto de fomentar el desarrollo de proyectos de energías renovables, en las cuales la energía eólica posee un rol preponderante. De mantenerse vigentes estas políticas, cumpliendo además con la Ley Nacional 27.191 recientemente sancionada, se espera un aumento considerable de la participación de la energía eólica dentro de la matriz energética nacional en los próximos años.

A medida que la potencia eólica instalada aumente dentro de una misma región, la energía suministrada por los parques eólicos puede representar un porcentaje considerable del total de energía dentro de una subred. Frente a esta problemática, el organismo encargado de la operación técnica del mercado eléctrico mayorista requerirá herramientas técnicas confiables para realizar un manejo óptimo de los recursos eléctricos del país, pudiendo prever, y aprovechar los momentos de alta producción de energía eólica, posibilitando la programación del despacho de energía en distintas escalas temporales en función de la disponibilidad de las distintas centrales que componen el sistema eléctrico nacional.

De forma general, para poder aprovechar de manera óptima el recurso energético proveniente del viento, distintos métodos de pronóstico de viento y potencia eléctrica han sido desarrollados y evaluados alrededor del mundo para distintos plazos de pronóstico. Algunos de los métodos propuestos han sido implementados operativamente en distintos países, en particular en aquellos lugares donde la energía eólica posee una participación considerable dentro de sus respectivos mercados eléctricos. Acompañando a esta necesidad existente, diversas empresas fueron creadas para prestar este tipo de servicios, entre las cuales se pueden mencionar Garrad Hassan, AWS Truepower, Enfor, entre otras. Mayormente este tipo de proveedores desarrollan y entregan pronósticos operativos de potencia eólica cumpliendo las especificaciones y reglamentaciones específicas de cada cliente, que incluyen desde los operadores del mercado eléctrico, hasta los propietarios de los parques eólicos.

Anticipándose al incremento del número de parques eólicos instalados en Argentina, la presente Tesis fijó como objetivo principal el desarrollo, documentación y evaluación de diversos métodos de pronóstico de viento y potencia eólica para distintos plazos de pronóstico, de forma tal de generar una herramienta de utilidad para la gestión de la energía

eólica a escala regional, tomando como caso de estudio en los primeros cuatro capítulos de la Tesis, el Parque Eólico Rawson, instalado en la región noreste patagónica. Asimismo se intentó que las metodologías propuestas se encuentren lo suficientemente detalladas y disponibles para toda la comunidad, para ser replicadas en otros parques eólicos.

Para llevar a cabo el trabajo de investigación, se contó con una completa base de datos de velocidad y dirección del viento, y potencia eólica del Parque Eólico Rawson (PER). Normalmente este tipo de información es muy difícil de adquirir debido a su carácter confidencial, y en el presente caso la misma fue suministrada por CAMMESA. Es entonces que esta Tesis documenta abiertamente, y por primera vez, el desarrollo de metodologías de pronóstico de potencia eólica hasta 48 hs para un parque eólico instalado en Argentina, y en particular en la Patagonia; una de las regiones continentales más ventosas del mundo. Si bien en el pasado se realizaron diversos trabajos científicos relacionados con energía eólica, los mismos estaban mayormente orientados al estudio del recurso eólico, con un enfoque climatológico del tema.

La caracterización de las variables que componen esta base de datos fue imprescindible para identificar las características principales de la variabilidad del viento y la potencia eléctrica en los alrededores del PER, y fue realizada en el Capítulo 2. En esta sección quedó evidenciado que existen variaciones locales de las características medias del viento y la potencia eléctrica, con una escala de variabilidad espacial menor a la del tamaño del parque eólico, que deben ser tenidas en cuenta para generar pronósticos más precisos de la potencia total que puede generar el PER. Para poder representar estas variaciones locales y entendiendo que las distintas configuraciones de los MNPT propuestos en capítulos posteriores no alcanzan la resolución espacial necesaria, se generaron curvas de potencia dependientes de la dirección del viento de forma tal incluir las variaciones espaciales de la potencia total del PER cuando el viento proviene de distintos sectores.

Actualmente la mayoría de los modelos de pronóstico de potencia eólica para plazos superiores a 6 horas incluyen en su formulación pronósticos de viento provenientes de MNPT. Existen muchos factores que pueden modificar el desempeño de los MNPT: la elección de la variable que se desea pronosticar, si la misma se encuentra por dentro o por fuera de la capa límite atmosférica, la resolución espacial utilizada, el conjunto de parametrizaciones elegido, los niveles verticales seleccionados, las condiciones iniciales y de borde (tanto para modelos globales como regionales), el dominio escogido, la región de estudio, entre otros factores. Por este motivo en el Capítulo 3 se analizó el desempeño de 5 configuraciones distintas del modelo regional WRF y el pronóstico determinístico del modelo global GFS, en la representación de la intensidad y dirección del viento en el PER, bajo la hipótesis que podría haber diferencias sustanciales al modificarse determinadas características de los experimentos. En particular se evaluó cada una de las configuraciones propuestas para la estación estival e invernal, analizando su desempeño a través de distintos índices de error para distintos plazos de pronóstico, condiciones de estabilidad y dirección del viento. Los resultados más importantes de este capítulo están asociados al beneficio sustancial que tiene la utilización de modelos regionales respecto del modelo global GFS, y un primer esbozo de que, incluso realizando un pequeño ensamble de pronósticos con 5 miembros, los errores en los pronósticos de viento se ven reducidos. Asimismo no existen diferencias significativas entre la utilización de los

pronósticos de viento a 10m o en el nivel más cercano a la altura de rotación de los aerogeneradores, una vez que los errores sistemáticos fueron removidos.

El Capítulo 4 presenta uno de los dos ejes fundamentales de esta Tesis. En esta sección se desarrollaron y evaluaron distintos métodos de pronóstico de viento y/o potencia eólica para distintos plazos de pronóstico. Cuando éstos eran menores a 6 horas, se escogieron métodos estadísticos debido a que en general tienen mejor desempeño que los métodos basados en MNPT. Los modelos autoregresivos propuestos en la Sección 4.2 mostraron una reducción del RMSE y NRMSE respecto de un modelo simple de referencia como la persistencia, mientras que los modelos espaciotemporales construidos en la Sección 4.3, enmarcados en un experimento teórico, mostraron a su vez resultados sustancialmente mejores que la persistencia, obteniendo reducciones del RMSE de la intensidad del viento superiores a 50% para la primer hora de pronóstico. Finalmente en la Sección 4.4 se propusieron modelos combinados de pronóstico de potencia eólica para plazos de hasta 48 hs, los cuáles incluían en su formulación los pronósticos de intensidad y dirección de viento de una de las configuraciones del modelo WRF propuestas en el Capítulo 3 y los pronósticos de GFS. Nuevamente encontramos el beneficio de utilizar el modelo regional obteniendo errores medidos a través del NMAE y NRMSE significativamente menores respecto de aquellos modelos construidos con los pronósticos de viento del modelo global. Sin embargo los errores encontrados son mayores a los documentados en otras regiones del mundo para terrenos con topografía simple.

La originalidad del tema de investigación a nivel local posee ciertas desventajas asociadas a la falta de documentación de trabajos similares en la misma región de estudio para realizar comparaciones. Más aún, es probado que los métodos de pronóstico de viento y potencia eólica varían en función de la región del mundo donde se encuentren instalados los parques eólicos, dificultando la identificación de un método de pronóstico como el más apropiado para todos los lugares del mundo. Es por eso que esta Tesis aporta un nuevo valor de referencia a vencer en futuros trabajos, de forma tal de desarrollar nuevos métodos que no sólo superen a la persistencia, sino también al desempeño de los modelos desarrollados a lo largo de este trabajo.

Dada la gran utilidad asociada a los pronósticos de potencia eólica y a través de un convenio de cooperación realizado entre el CIMA y CAMMESA, los métodos de pronóstico de potencia a corto plazo (6 hs) basados en el desarrollo de la Sección 4.2 y los métodos de pronóstico combinados desarrollados en la Sección 4.3, serán adaptados a una versión operativa, resultando en herramientas de decisión operativas que colaboren con la toma de decisiones y la programación diaria de despacho de energía, optimizando el recurso energético a nivel nacional. La versión operativa de estos modelos estará focalizada en primera instancia en el PER, pero dado su carácter replicable, se espera que estos mismos métodos puedan aplicarse a nuevos parques eólicos, habiendo sido especificados para estos nuevos sitios. Más aún, este convenio es superador en el sentido de que no se trata de suministrar un sistema de pronóstico cerrado a CAMMESA, sino que sea esta compañía quién pueda manejar y modificar la operación del sistema, para lo cual se trabajó conjuntamente en esta transferencia tecnológica adaptando y documentando las metodologías seleccionadas, y realizando la implementación operativa específica en las instalaciones de CAMMESA.

Finalmente el Capítulo 5 de la Tesis se alejó de la región patagónica, llevándose a cabo diversos análisis utilizando para ello una de las bases de datos de potencia eólica más completa del mundo, compuesta con la información de más de 300 parques eólicos instalados en Dinamarca. En este capítulo se desarrollaron y evaluaron métodos de pronóstico combinados de potencia eólica para cada parque instalado en la región. Sin embargo el resultado más original de esta sección está asociado a la generalización espacial de los modelos de pronóstico, considerando que los coeficientes específicos de los modelos construidos para cada parque eólico responden a un patrón espacial, pudiéndose inferir sus valores en nuevos sitios utilizando para ellos los coeficientes aledaños. De esta manera se posibilitó la implementación de un modelo simplificado como WPPT desde el inicio de operación de un parque, con una ganancia promedio de 22 semanas de tiempo de recolección de datos de potencia y realización de pronósticos de viento a través de MNPT. Este trabajo fue realizado en la Universidad Tecnológica de Dinamarca (DTU) a través de una estadía de 3 meses de duración.

A lo largo de los 5 capítulos, luego de realizar una completa revisión bibliográfica del problema y a partir de reuniones y experiencia ganada con los distintos actores asociados a esta temática, es posible identificar algunas líneas generales de trabajo a desarrollar en el futuro:

Respecto de los pronósticos para plazos menores a 6 horas basados en series temporales, existen diversas metodologías que no han sido exploradas en esta Tesis y que sería importante considerar. Redes Neuronales, Support Vector Machines, entre otras metodologías deberían probarse para evaluar su impacto en la mejora de los pronósticos de potencia. Asimismo los modelos espaciotemporales analizados en la Sección 4.3 fueron basados en un experimento idealizado y sería muy interesante poder realizar un estudio análogo utilizando datos de viento medidos en otras estaciones meteorológicas en las cercanías del PER, obteniendo resultados más realistas del problema.

Los pronósticos combinados de potencia eléctrica para plazos de hasta 48 hs no han sido muy sensibles a las distintas configuraciones del modelo WRF. Sin embargo, y a pesar de que solo se consideraron 5 miembros, parece ser que los pronósticos por ensambles podrían reducir los errores en los pronósticos de viento, y por ende en la potencia eólica. Además se utilizaron como condiciones iniciales y de borde los análisis y pronósticos del modelo global GFS. Por tanto, también sería un buen ejercicio realizar los mismos experimentos utilizando, por ej, el modelo numérico del European Centre for Medium-Range Weather Forecasts (ECMWF).

El contexto operativo de la aplicación de estos modelos implica además realizar una debida actualización recurrente de los distintos parámetros que permiten construir los modelos, ya que no sólo cambian los regímenes de viento a lo largo de los meses, sino también puede haber modificaciones en el entorno de los parques eólicos, cambios en las configuraciones de los MNPT involucrados, e incluso desgaste de las piezas de los aerogeneradores que pueden provocar una respuesta diferente a lo largo del tiempo. Dada la gran cantidad de datos asociados a estos modelos, queda explorar formas eficientes para actualizar sistemáticamente estos modelos.

Complementariamente queda por resolver el problema de las “Rampas de Potencia”, tema que no fue objeto de ser desarrollado en la presente Tesis. Las Rampas de Potencia se refieren

a cambios abruptos de generación de energía eólica en un plazo de tiempo corto (existen varias definiciones dependientes de las ventanas temporales propuestas), las cuales pueden estar asociadas a un fuerte y rápido incremento o disminución de la potencia eólica, pudiendo ocasionar, de no ser previstos, daños en las redes eléctricas.

Acrónimos

ANN	Artificial Neural Networks
AR	Modelos Autoregresivos
ARMA	Modelos Autoregresivos de Medias Móviles
ARW	Advanced Research WRF
CAMMESA	Compañía Administradora del Mercado Mayorista Eléctrico S.A
CIMA	Centro de Investigaciones del Mar y la Atmósfera
CLA	Capa Límite Atmosférica
DMI	Denmark Meteorology Institute
DTU	Denmark Technical University
ECMWF	European Centre for Medium-Range Weather Forecasts
ESRL	Earth System Research Laboratory
GEI	Gases de Efecto invernadero
GFS	Global Forecast System
GWEC	Global Wind Energy Council
HIRLAM	Hi Resolution Limited Area Model
HOA	Hora Oficial Argentina
KO	Kriging Ordinario
MAE	Mean Absolute Error
MET	Modelos Espacio Temporales
MMM	Mesoscale and Microscale Meteorology
MNPT	Modelos numéricos de pronóstico del tiempo
NCAR	National Center for Atmospheric Research
NCEP	National Center for Environmental Prediction

NMAE	Normalized Mean Absolute Error
NMM	Nonhydrostatic Mesoscale Model
NOAA	National Oceanic and Atmospheric Administration
NRMSE	Normalized Root Mean Square Error
PER	Parque Eólico Rawson
RMSE	Root Mean Square Error
SRTM	Shuttle Radar Topography Mission
WAsP	Wind Atlas Analysis and Application Program
WPPT	Wind Power Prediction Tool
WRF	Weather Research and Forecast