



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY



Pronóstico de Energía Eólica para Horizontes Temporales de Corto Plazo en Base a Modelo Numérico de Mesoescala y Redes Neuronales Artificiales

Everton de Almeida Lucas

Programa de Posgrado en Ingeniería de la Energía
Facultad de Ingeniería
Universidad de la República

Montevideo – Uruguay
Mayo de 2019



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY



Pronóstico de Energía Eólica para Horizontes Temporales de Corto Plazo en Base a Modelo Numérico de Mesoescala y Redes Neuronales Artificiales

Everton de Almeida Lucas

Tesis de Maestría presentada al Programa de Posgrado en Ingeniería de la Energía, Facultad de Ingeniería de la Universidad de la República, como parte de los requisitos necesarios para la obtención del título de Magíster en Ingeniería de la Energía.

Director:

Dr. Ing. Prof. Alejandro Gutiérrez Arce

Codirector:

Dr. Prof. Sandro da Silva Camargo

Montevideo – Uruguay

Mayo de 2019

de Almeida Lucas, Everton

Pronóstico de Energía Eólica para Horizontes Temporales de Corto Plazo en Base a Modelo Numérico de Mesoescala y Redes Neuronales Artificiales / Everton de Almeida Lucas. - Montevideo: Universidad de la República, Facultad de Ingeniería, 2019.

XIV, 154 p. 29, 7cm.

Director:

Alejandro Gutiérrez Arce

Codirector:

Sandro da Silva Camargo

Tesis de Maestría – Universidad de la República, Programa en Ingeniería de la Energía, 2019.

Referencias bibliográficas: p. 99 – 108.

1. Energías Renovables, 2. Inteligencia Artificial, 3. Modelo Físico de Pronóstico, 4. Modelo Estadístico de Pronóstico, 5. Despacho Económico de Energía Eléctrica. I. Gutiérrez Arce, Alejandro, *et al.* II. Universidad de la República, Programa de Posgrado en Ingeniería de la Energía. III. Título.

INTEGRANTES DEL TRIBUNAL DE DEFENSA DE TESIS

Dr Ing. Prof. José Cataldo

Dr. Prof. Marcelo Romero

Dra Prof. Aiala Rosá

Montevideo – Uruguay
Mayo de 2019

Dedico este trabajo con mucho
cariño y amor para mi familia.

Agradecimientos

En primer lugar agradezco a mi familia, por la enseñanza de valores humanos y morales imprescindibles para la vida. También les agradezco por el apoyo incondicional en todos los ámbitos, el cual fue imprescindible para que se pudiera llegar a este momento.

Agradezco a mis amigos, los cuales considero parte de mi familia. A estos incluyo principalmente a los que la vida me presentó como unos “hermanos” más.

Agradezco a mi tutor, Prof. Dr. Ing. Alejandro Gutiérrez, por todo el aporte técnico para este trabajo, por la amistad y también por todo el esfuerzo que hizo para que se concretara este trabajo, frente a inúmeros desafíos que surgieron a lo largo del desarrollo de esta tesis.

Agradezco a mi cotutor, Prof. Dr. Sandro da Silva Camargo, por todo el aporte técnico en la parte de redes neuronales artificiales, además de su disponibilidad y humildad en transmitir su conocimiento.

Agradezco al Prof. Dr. Ing. José Cataldo, el cual fue una persona muy importante para mi llegada al Instituto de Mecánica de los Fluidos e Ingeniería Ambiental (IMFIA). Le agradezco también por las oportunidades que me fueron concedidas de participación en proyectos de investigación en el tema de energía eólica, en los cuales el aprendizaje adquirido fue muy importante para entender todo el contexto en que está inserida la energía eólica.

Agradezco al Prof Dr. Gabriel Cazes, por su humildad en transmitir su conocimiento de manera clara y objetiva.

Agradezco al Prof. Dr. Marcelo Romero, el cual fue el responsable por ofrecerme la primer oportunidad a nivel académico en participar de proyectos de investigación en pronósticos de energía eólica. Esta experiencia fue imprescindible para el desarrollo de conocimiento en el tema.

Agradezco a los integrantes del tribunal, Aiala Rosá, Marcelo Romero y José Cataldo por todos los aportes hechos a partir de las correcciones, las

cuales incrementaron mejoras al trabajo desarrollado.

Agradezco a la Empresa Eléctrica UTE por disponibilizar algunos de los datos que se utilizaron para este trabajo y fueron imprescindibles para el desarrollo de la tesis. Además les agradezco, juntamente con la Fundación Julio Ricaldoni por la financiación del modelo de pronóstico operativo de energía eólica desarrollado por el IMFIA, el cual fue una importante referencia y base de conocimiento.

Agradezco a la Universidad de la República, la Facultad de Ingeniería, y más específicamente al Instituto de Mecánica de los Fluidos e Ingeniería Ambiental (IMFIA), por toda la estructura disponibilizada.

Por fin, agradezco a todas las otras personas que no están mencionadas en esta sección, pero que de una manera u otra, tuvieron su aporte para fueron dadas las condiciones para el desarrollo de esta tesis.

RESUMEN

En Uruguay se tiene el 34.43 % de la matriz energética de origen eólico. Dada esta realidad, y la característica fluctuante del viento en la atmósfera terrestre a escala horaria, es necesario incorporar modelos de pronósticos de energía eólica, de modo de suministrar informaciones de la generación de energía con anticipación, para que se logre hacer el despacho óptimo de energía en el sistema eléctrico. En este trabajo de tesis, se consideran los datos de generación de energía eléctrica de los parques eólicos en Uruguay, pronósticos numéricos de mesoescala referentes al mismo período de los datos de generación de los parques y el análisis del comportamiento de distintas variables atmosféricas en el período histórico de generación de energía. Con estos datos se busca optimizar los pronósticos de energía eólica en Uruguay en base a la utilización del modelo numérico de mesoescala WRF-ARW y de redes neuronales artificiales (RNA). Se evalúan ocho modelos de pronóstico de energía eólica, basados en modelos híbridos, con el uso del modelo numérico de mesoescala WRF-ARW junto a redes neuronales artificiales (WRF-RNA) y modelo numérico WRF-ARW junto a regresiones lineales (WRF-RL). Los resultados fueron evaluados para un total de 31 parques eólicos (1267,4 Megawatts (MW)) y el modelo que mostró el mejor desempeño fue un modelo híbrido del tipo WRF-RNA, con datos de velocidad del viento sin corrección por análisis cluster, presentando un error medio absoluto de aproximadamente 17 % considerando pronósticos individuales para cada parque eólico. En un análisis del ciclo diario, considerando un pronóstico con la suma de potencia de todos los parques eólicos, los resultados muestran los valores de sesgo (bias) más cercanos al cero para todos los modelos en base a WRF-RNA, así como menores valores de error medio absoluto (entre 10 % y 6.5 %), comparado con el modelo WRF-RL (entre 14 % y 9 %). De acuerdo a los resultados obtenidos, se verifica que una combinación de un modelo físico con modelo de redes neuronales artificiales, parece ser una

gran herramienta para el pronóstico de la energía eólica.

Palabras claves:

Energías Renovables, Inteligencia Artificial, Modelo Físico de Pronóstico,
Modelo Estadístico de Pronóstico, Despacho Económico de Energía Eléctrica.

ABSTRACT

In Uruguay, 34.43 % of mix of energy comes from wind power generation. Due to this importance, and also the fluctuating characteristic of wind at atmospheric boundary layer, wind power generation forecast model becomes a massive requirement. Such technique has a tremendous impact on providing information on energy generation in advance, in order to guarantee a steady dispatch of electricity through the entire power system. In this thesis, we consider the data of electric power generation of the wind farms in Uruguay, mesoscale numerical forecasts referring to the same period of generation data of the parks and the analysis of behavior of different atmospheric variables in the historical generation period of energy. With these data, it is sought to optimize wind energy forecasts in Uruguay in based on the use of the mesoscale numerical model WRF-ARW and artificial neural networks (RNA). In this thesis, eight models of wind energy forecast - based on hybrid models are evaluated with the use of the mesoscale numerical model WRF-ARW along with artificial neural networks (WRF-RNA), and model numerical WRF-ARW with linear regressions (WRF-RL). The results were evaluated for a total of 31 wind farms (1267.4 Megawatts (MW)). The model that revealed best performance was the hybrid model of the WRF-RNA type, with wind speed data without correction by cluster analysis. Such model presented an absolute average error of approximately 17 %, considering individual forecasts for each wind farm. In an analysis of daily cycle, considering a forecast with the sum of power of all the wind farms, results shown the bias values (bias) closest to zero for all models based on WRF-RNA. Also, shown lower values of absolute mean error (between 10 % and 6.5 %), when compared to the WRF-RL model (between 14 % and 9 %) . According to results obtained, it is verified that a combination of a physical model with an artificial neural network model, represents a great tool for forecast of wind energy generation.

Keywords:

Renewable Energy, Artificial intelligence, Physical Forecast Model,
Statistical Forecast Model, Economic Dispatch of Electric Power.

Tabla de contenidos

1	Motivación	1
2	Introducción	3
3	Energía Eólica	13
3.1	El Viento	13
3.2	Energía Eólica	18
4	Sistema Eléctrico en Uruguay	26
5	Modelo Numérico de Mesoescala	37
5.1	Parametrizaciones Físicas	43
5.1.1	Radiación y Microfísica	43
5.1.2	Cumulus y Tormentas Convectivas	44
5.1.3	Intercambio de calor con la superficie	44
5.1.4	Capa Límite Atmosférica y Capa de Superficie	44
5.2	Modelos de Pronóstico Operativo	45
6	Redes Neuronales Artificiales	47
6.1	Histórico de las RNA's	49
6.2	Inspiración Biológica	52
6.3	Neurona Artificial	54
6.3.1	Funciones de Activación	57
6.4	Arquitecturas de RNA	62
6.4.1	Redes de Capa Única	63
6.4.2	Redes Multicapa	63
6.4.3	Redes Recurrentes	65
6.5	Algoritmos de Entrenamiento	66
6.5.1	Retropropagación	68

6.6	Métricas de Evaluación	74
7	Metodología	77
7.1	Parques Eólicos y Torres de Mediciones Utilizadas para el Estudio	77
7.2	Modelo Numérico WRF-ARW	80
7.3	Configuración Cluster	82
7.3.1	Técnicas de pronóstico	84
8	Resultados	91
9	Conclusiones	96
	Referencias bibliográficas	99
	Apéndices	109
	Apéndice 1 Análisis Cluster - Parametrización Mellor-Yamada-Janjic.	110
	Apéndice 2 Continuación de Análisis Cluster - Parametrización Mellor-Yamada-Janjic.	120
	Apéndice 3 Análisis Cluster - Parametrización Yonsei University.	123
	Apéndice 4 Continuación de Análisis Cluster - Parametrización Yonsei University	133
	Apéndice 5 Modelos de Pronóstico	137
5.1	Modelos Basados en Regresión Lineal	137
	Apéndice 6 Modelos de Pronóstico	146
6.1	Modelos Basados en Redes Neuronales Artificiales	146

Capítulo 1

Motivación

En ingeniería los desafíos son el punto de partida para la resolución de los problemas y para el desarrollo tecnológico. Este trabajo trata de un desafío tecnológico enfrentado por los sistemas eléctricos actuales, que necesitan cada vez más conocer de forma anticipada y lo más precisa posible, la variabilidad espacial y temporal de las fuentes de energías renovables no convencionales (eólica y solar principalmente), para operar, gestionar y planificar de manera óptima el sistema eléctrico. Aportar conocimiento de modo de propiciar un desarrollo sustentable, o sea, satisfacer las necesidades del presente sin comprometer las necesidades del futuro, fue uno de los principales factores que impulsó el desarrollo de la energía eólica a nivel mundial.

Para implementar a gran escala la energía eólica, se requiere estudiarla y conocer el comportamiento del viento en la capa límite atmosférica. En base a su variabilidad espacial y temporal, pronosticarlo es de suma importancia para aumentar la eficiencia del uso de esta fuente de energía en los sistemas eléctricos. Mejorar los pronósticos de generación de energía eléctrica a partir de los parques eólicos es algo imprescindible. Algunas preguntas que orientaron este trabajo son: ¿Cómo generar pronósticos con alto nivel de precisión? ¿Cómo sacar el máximo provecho de datos históricos de generación de los parques eólicos? ¿Es posible crear un modelo que además de pronosticar el futuro basado en condiciones iniciales de la atmósfera pueda tener en cuenta un conocimiento en base a los eventos anteriores?

Siendo los pronósticos del viento imprescindibles para los actuales sistemas eléctricos, entonces el camino es mejorarlos. Conociendo el recurso eólico local se puede estimar su comportamiento no lineal y estocástico con un buen mar-

gen de precisión. Siendo el comportamiento del viento no lineal, este trabajo se enfocó en el uso de modelos numéricos de mesoescala junto a modelos no lineales de postprocesamiento. A partir de estas ideas es que se buscó aplicar las redes neuronales artificiales, las cuales adquieren “conocimiento” basados en el aprendizaje de los eventos históricos, como la generación de energía eléctrica en distintas condiciones de la atmósfera.

Se describe el contenido de la tesis, luego de haber presentado la motivación para el desarrollo del tema propuesto. El capítulo 2 presenta una breve introducción sobre el contexto en que está la energía eólica a nivel mundial, regional y local. En el capítulo 3 se describen los fundamentos de la transformación de la energía cinética del viento en energía eléctrica. Son descriptos los factores más importantes a considerar sobre el comportamiento del viento en la capa límite atmosférica. El capítulo 4 presenta una breve descripción del sistema eléctrico Uruguayo. En el capítulo 5 se describen los modelos numéricos de mesoescala, y se hace una breve explicación sobre los modelos de pronósticos operativos de energía eólica. En el capítulo 6 se describen los conceptos básicos de redes neuronales artificiales. En dicho capítulo se presenta un breve histórico sobre el desarrollo de las RNA's, la inspiración en las neuronas biológicas, los conceptos de las neuronas artificiales, las principales funciones de activación y arquitecturas de las RNA's. Por fin, en el mismo capítulo 6, se presentan de modo más detallado el algoritmo de entrenamiento de retropropagación, el cual fue el utilizado para el desarrollo de esta tesis y las métricas de evaluación del proceso de aprendizaje de una red neuronal artificial. El capítulo 7 presenta la metodología utilizada para el desarrollo de esta tesis, el capítulo 8 los resultados de los modelos de pronósticos desarrollados, y en el capítulo 9, se presentan las conclusiones acerca de los resultados de los pronósticos desarrollados y las principales contribuciones de esta tesis.

Capítulo 2

Introducción

En las últimas décadas el desarrollo a nivel mundial ha tenido como principio común el denominado “desarrollo sustentable”, lo cual se define según [ONU \(1987\)](#), como “*la satisfacción de las necesidades de la generación presente sin comprometer la capacidad de las generaciones futuras para satisfacer sus propias necesidades*”. Dicho concepto está basado en tres pilares principales, que son el desarrollo económico, desarrollo social y la protección del medio ambiente, los cuales buscan un desarrollo de manera equilibrada.

La energía es un tema central para lograr el desarrollo sustentable, pues está directamente involucrada en los tres pilares principales del desarrollo sustentable. Antecedentes de crisis energéticas a nivel mundial mostraron el fuerte impacto causado a la sociedad. La primera crisis energética, fue la llamada “primera crisis del petróleo”, en el año 1973, que se dio a partir del aumento brusco de precio del barril de crudo y recorte de suministro de los países miembros de la [OPEP \(2018\)](#)¹ a los países que apoyaban Israel en la guerra de Yom Kippur. Esta crisis tuvo como consecuencia una escasez de petróleo a nivel mundial, teniendo fuertes impactos en el ámbito económico y social. Estos impactos afectaron incluso a países muy fuertes económicamente, como los países desarrollados de Europa, y Estados Unidos, que desde aquella época se ubicaba como una de las mayores potencias económicas del mundo [Issawi \(1978\)](#), [Lin \(1984\)](#). Dicha crisis ocasionó cambios importantes en las políticas energéticas a nivel mundial entre las cuales se destacan: la explota-

¹OPEP (Organización de Países Exportadores de Petróleo) es una organización intergubernamental fundada en 1960. Actualmente cuenta con 14 países miembros que son Irán, Irak, Kuwait, Arabia Saudita, Venezuela, Indonesia, Libia, Emiratos Arabes Unidos, Argelia, Nigeria, Ecuador, Angola, Guine Ecuatorial y Congo.

ción del petróleo en los países de la OPEP pasa a ser realizado en su mayoría por empresas nacionales (buscando mayor soberanía nacional); desarrollo de la energía nuclear (principalmente en Francia); explotación de yacimientos de petróleo en sitios antes no explorados (Mar del Norte y Alaska) y la creación de los primeros programas de investigación para el desarrollo de los primeros aerogeneradores rentables económicamente.

Luego en el año 1979, se dio la “segunda crisis del petróleo”, a partir de una guerra entre dos grandes productores de petróleo a nivel mundial, Irán e Irak. Esta guerra hizo que la producción mundial de petróleo estuviera afectada debido a que muchos de los yacimientos petroleros de ambos países sufrieron daños estructurales. La baja en el suministro de petróleo, ocasionó un fuerte aumento del precio del crudo a nivel mundial, teniendo impactos similares a la primera crisis del petróleo.

Las dos crisis del petróleo mostraron la importancia de desarrollar una soberanía energética en base a una diversificación de la matriz energética, buscando una menor dependencia de fuentes de energía que están sobre el control de algunos pocos países, que en determinadas conyunturas políticas pueden manejar el precio y el suministro. En el siglo XXI, los precios del crudo del petróleo tuvieron alzas considerables en dos periodos: 2004-2008 debido a una burbuja de precios ocasionada por la alta demanda de China e India y 2009-2013 debido a la alta demanda de los países emergentes.

La figura 2.1 presenta el histórico de los precios (en dólares estadounidenses ajustados por la inflación, utilizando el índice de precios al consumidor (IPC)) del barril de petróleo crudo, del año 1970 hasta 2018, con tomadas de precio en el mes de Enero de cada año.

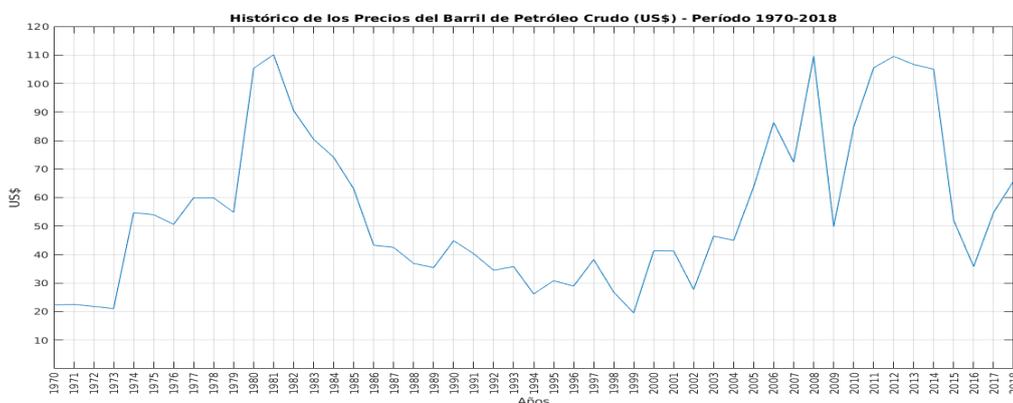


Figura 2.1: Histórico de precios del barril de petróleo crudo, del año 1970 hasta 2018. Fuente: Adaptado de [Macrotrends \(2018\)](#).

En la figura 2.1 es posible verificar la gran variabilidad de precio del barril de petróleo, lo que dificulta las planificaciones económicas en países que son altamente importadores de este tipo de fuente de energía.

Algunos países, como Dinamarca, a partir de las crisis del petróleo hicieron una política de planificación a largo plazo para diversificar las fuentes de energía del país. Tal planificación se hizo buscando una mayor soberanía frente a la variabilidad de precios del petróleo, de modo de atenuar sus consecuencias en la economía Rüdiger (2014), Agency (2012).

Además de los problemas que fueron enfrentados por diversos países en las dos crisis del petróleo de los años 70, en la misma década se sumó la preocupación ambiental, debido a las emisiones de gases de efecto invernadero, principalmente el dióxido de carbono (CO_2), en la atmósfera terrestre. La emisión de gases de efecto invernadero se produce debido al proceso de combustión de los combustibles fósiles, como el carbón mineral, gas natural y el petróleo. Con esta preocupación a nivel mundial, surgieron a partir de la Organización de las Naciones Unidas ONU (2018) las llamadas cumbres del clima, entre las cuales se puede destacar la primera conferencia mundial sobre el clima en Estocolmo, Suecia ONU (1972), cumbre de la tierra en Río de Janeiro, Brasil ONU (1992), cumbre del clima de París, Francia ONU (2015), entre otras que tuvieron un importante rol en cuanto a la concientización política y social a nivel mundial, referente al tema ambiental. Como resultado de las cumbres del clima, se destacan algunos tratados, como el Protocolo de Kyoto, ONU (1998) que entró en vigor en 2005, y logró un acuerdo internacional para reducir las emisiones de gases de efecto invernadero, con el objetivo de reducción de al menos un 5% de la emisión en el periodo 2008-2012 en relación al año 1990. Siguiendo la misma línea de preocupación ambiental, surge en 1988, el Panel Intergubernamental del Cambio Climático (IPCC, del inglés), con el objetivo de promover evaluaciones regulares del cambio climático con base científica, mostrando los impactos y riesgos futuros, y las opciones para adaptación y mitigación de estos impactos, IPCC (2019).

Otro factor que potencializó la importancia del desarrollo de las energías renovables, fue el accidente nuclear de Chernobyl, en 1986, que generó y sigue generando problemas en diversos ámbitos a nivel mundial.

En este contexto a nivel mundial, de la búsqueda por una mayor soberanía energética/política/económica y además buscar disminuir las emisiones de gases de efecto invernadero, es que surge el interés en el desarrollo tec-

nológico de las energías renovables/alternativas no convencionales, como la eólica y solar principalmente. Se introdujo el desafío de modificar las matrices energéticas predominantemente compuestas por combustibles fósiles. Además del tema ambiental, con la preocupación del recurso finito de los combustibles fósiles, precios fluctuantes del barril de petróleo sujetos a cuestiones de ámbito político y la importancia de diversificar las fuentes de energía como forma de soberanía nacional, surgen los esfuerzos para el desarrollo de las fuentes de energías renovables, en particular la eólica.

Frente a estos desafíos, las energías renovables tuvieron un rápido desarrollo tecnológico en las últimas décadas. Estos desarrollos promovieron un rápido incremento de estas tecnologías en los sistemas eléctricos a nivel mundial. La implementación de las energías renovables, además de disminuir porcentualmente las emisiones de gases en la atmósfera terrestre por energía eléctrica producida (kWh o MWh), también promovieron una baja del costo de esta energía (relación USD/kWh o USD/MWh). La figura 2.2 presenta el *costo nivelado global de electricidad* en USD/kWh (tomando la cotización del dólar año 2016) de las principales fuentes de energía renovable, del periodo de 2010-2017.

1

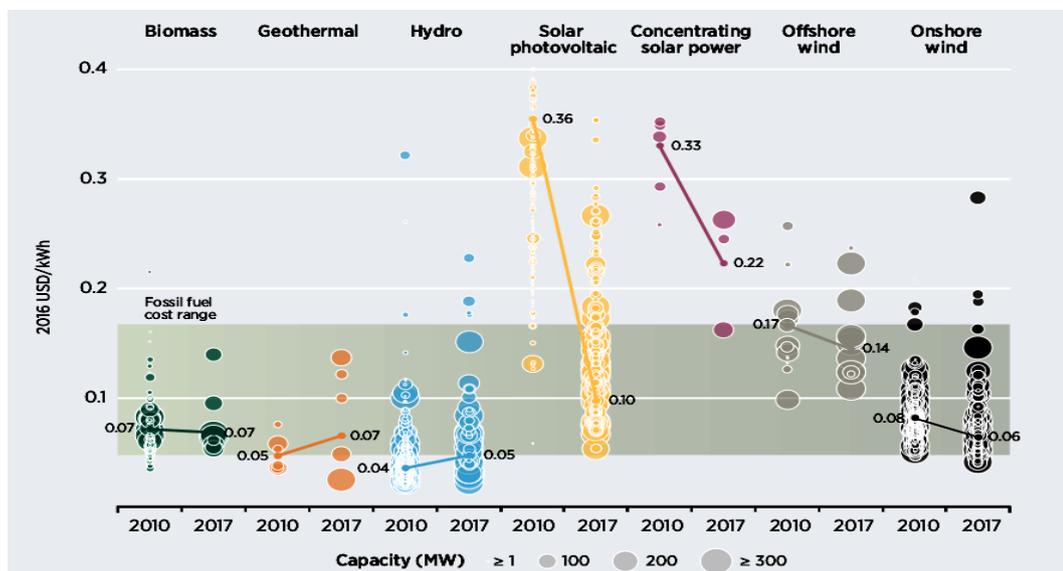


Figura 2.2: Costo (USD/KWh) de la energía eléctrica proveniente de fuentes de energías renovables, para el período 2010-2017. La franja horizontal gris presenta el rango de costo de las fuentes de energía de combustibles fósiles. Fuente: IRENA (2017), International Renewable Energy Agency.

¹El costo nivelado es una relación entre el costo de vida útil de una planta de generación por la generación de electricidad en este periodo.

En base a la figura 2.2, es posible verificar que los costos de la mayoría de las fuentes de energía renovable tuvieron un decrecimiento en los últimos años y además están dentro del rango de costos de las fuentes de combustibles fósiles. Las únicas dos fuentes que tuvieron un incremento en el costo, fueron la geotérmica y la hidroeléctrica, siendo este incremento causado por la disminución de sitios que necesitaban menos inversiones, debido a las condiciones favorables para la explotación. De acuerdo a IRENA (2017), tres factores son los principales para la reducción de costos de las energías renovables: mejoras en la tecnología, contratación competitiva y la gran base de experiencia internacional de los desarrolladores de proyectos. Este desarrollo permite a los países la oportunidad de una mayor soberanía energética, que consecuentemente logre una planificación energética, política y económica menos sujeta a factores externos, Rüdiger (2014), Agency (2012).

La energía eólica también tuvo la aceptación social y la descentralización del desarrollo como factores importantes para su incremento en la matrices energéticas a nivel mundial. Estas características hicieron que la energía eólica tuviera un rápido y fuerte incremento. La figura 2.3 presenta la capacidad instalada acumulada (MW) de energía eólica a nivel mundial del año 2001 hasta el 2017.

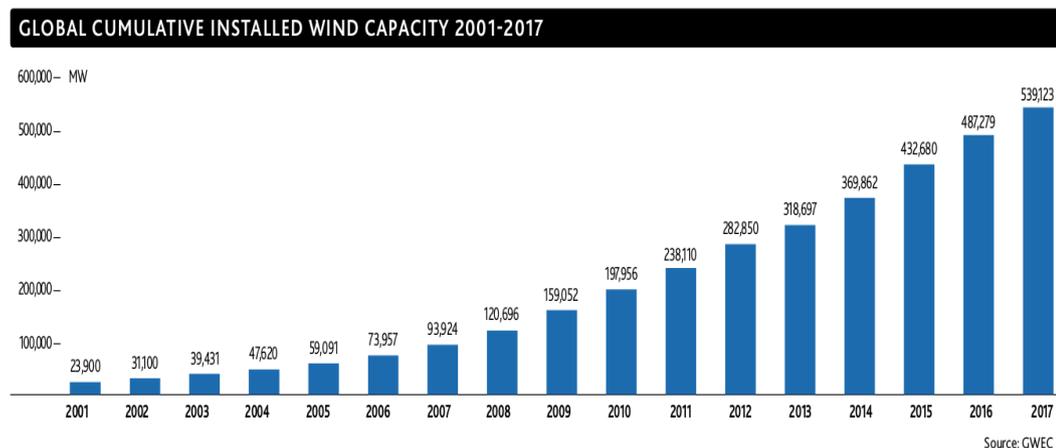


Figura 2.3: Capacidad instalada acumulada (MW) de energía eólica a nivel mundial del año 2001 hasta 2017. Fuente: GWEC (2018), Global Wind Energy Council.

Según GWEC (2019), la capacidad instalada acumulada al final del año 2018, fue de 591 GW (591.000 MW), número que representa un incremento de 9.6 % comparado al final del año 2017.

En Sudamérica, Uruguay se destaca por el significativo porcentaje de

energía eólica en la matriz energética (34.43 %, de acuerdo a [UTE \(2019\)](#)). La política energética implementada a partir del año 2008 en Uruguay, es reconocida a nivel mundial como unos de los principales casos de éxito en la implementación de la energía eólica en larga escala. Dicha política adoptada, permitió al país reducir los riesgos de seguridad energética a nivel nacional, pasando de ser un país netamente importador a un exportador de energía eléctrica en la región, [ADME \(2018\)](#), y además tiene su contribución para la cuestión climática, [GWEC \(2018\)](#). En la misma región, Brasil se destaca por la gran capacidad instalada (15.000 MW o 15 GW y 601 parques eólicos, de acuerdo a [ABEEólica \(2019\)](#)), que lo pone en la lista de los 10 países con mayor potencia eólica instalada a nivel mundial, [GWEC \(2018\)](#). En términos de porcentaje, la energía eólica en Brasil posee actualmente un 9.2 % de la matriz eléctrica en términos de potencia instalada, lo que ubica esta fuente de energía como la segunda en capacidad instalada en la matriz brasileña, [ABEEólica \(2019\)](#).

A su vez, Argentina, recién a partir del año 2015 empezó a desarrollar una política energética orientada al abastecimiento de energía eléctrica a partir de fuentes renovables. Esta política llevada a cabo, se dio a partir del plan RenovAR, [RenovAR \(2015\)](#). Por su reciente política de implementación de energías renovables, en fines de 2017, Argentina poseía solamente 228 MW instalados, [GWEC \(2018\)](#), siendo este valor bajo si se compara a los países vecinos, Uruguay y Brasil.

El alto incremento de la participación de la energía eólica en los sistemas eléctricos introdujo nuevos desafíos en la gestión de los sistemas eléctricos debido a la característica fluctuante a escalas horarias del recurso eólico, [Ackermann \(2005\)](#). En la gestión del sistema eléctrico se deben considerar las fluctuaciones a escalas horarias de modo de optimizar los costos de operación, la calidad de la energía (tensión y frecuencia constantes), [Ackermann \(2005\)](#), [Georgilakis \(2008\)](#) y balance entre demanda y generación de energía eléctrica. Buscar diversificar las fuentes de generación de energía en las matrices energéticas, agregando las renovables que tienen características de recurso fluctuante en el tiempo, como la eólica y solar, sin generar ineficiencias en el sistema eléctrico, es el principal desafío actualmente del sector eléctrico.

De acuerdo a [Gutiérrez \(2011\)](#), dada la naturaleza del recurso eólico, resulta de suma utilidad disponer de una herramienta que pronostique la generación de energía eólica que se tendrá en el futuro con bajos niveles de errores, de

tal forma de bajar la incertidumbre en el despacho de energía en el sistema eléctrico. Un pronóstico de generación de energía eólica con bajos niveles de errores a distintos horizontes temporales resulta en una gran herramienta para respaldar la gestión y planificación óptima de todo un sistema eléctrico con alto incremento de eólica. La figura 2.4 presenta de manera resumida el gran desafío del despacho de cargas, que es asegurar a cada instante la generación eléctrica requerida para atender la demanda, manteniendo el equilibrio del sistema.

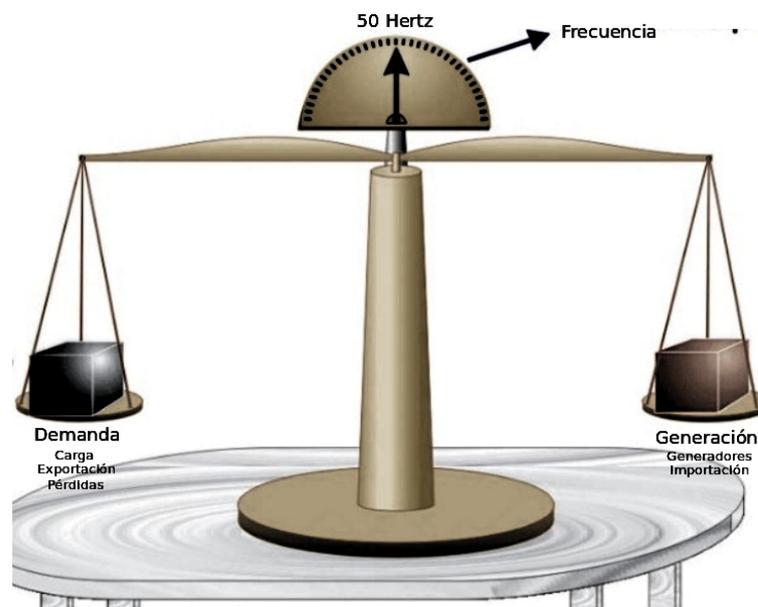


Figura 2.4: Representación de los desafíos del despacho de energía eléctrica. Fuente: Adaptado de UTE-DPE (2013) y ONS (2018).

En base a la figura 2.4, en caso de una generación de energía menor que la demanda, la frecuencia del sistema disminuye, en caso contrario, aumenta la frecuencia del sistema. En casos límite, con la generación mayor que la demanda el sistema eléctrico “corta” una parte de la generación, pero si la generación es menor que la demanda, el ERAC (esquema de rechazo automático de carga) busca “cortar” algunas de las cargas del sistema, de modo a mantener el equilibrio. Además de mantener el equilibrio del sistema, el despacho de cargas busca hacerlo de forma óptima (a mínimo costo) en los diferentes horizontes de tiempo, UTE-DPE (2013). De modo a realizar el despacho óptimo, se busca pronosticar la demanda y la generación de energía eléctrica, para distintos horizontes temporales.

Los pronósticos del viento se clasifican de acuerdo al horizonte temporal a pronosticar, y pueden ser de muy corto plazo (hasta 8 horas), de corto plazo

(hasta 24 horas) y de largo plazo (múltiples días (más de 24 horas)), Wang (2011). Pronosticar la generación de un parque eólico implica pronosticar variables atmosféricas que influyen en la generación de energía eólica, como la velocidad del viento y la densidad del aire en la altura del buje de los aerogeneradores, Soman (2015), De Almeida (2016), entre otras que puedan tener influencia, como la dirección del viento, por ejemplo. Para el despacho de energía eléctrica en el sistema se tiene la necesidad de que el pronóstico tenga informaciones de todos los horizontes temporales, los cuales pueden indicar desde eventos de mesoescala que ocurrirán en los próximos días, así como eventos de horizontes de tiempo más cortos (hasta 6 horas), De Mello (2015), como los eventos de rampa, Gutiérrez (2015), Castillo (2015), Gutiérrez (2018b). La tabla 2.1, presenta la aplicación de pronóstico con su respectivo horizonte temporal pronosticado, y su aplicación para la operación del sistema eléctrico.

Tabla 2.1: Aplicación de pronóstico con distintos horizontes temporales y sus aplicaciones de gestión y planificaciones en la operación del sistema eléctrico. Fuente: Adaptado de Wang (2011).

Horizonte de Pronóstico	Aplicación en el Sistema Eléctrico
Muy Corto Plazo	Operaciones en tiempo real y acciones de regulación
Corto Plazo	Despacho económico de carga y seguridad operacional
Largo Plazo	Mantenimiento y optimización de costo operacional

Los pronósticos del viento se dividen en dos tipos, que son el método físico y el método estadístico, Wang (2011). Los métodos estadísticos son de aplicación en el muy corto plazo, y tienen en general una mejor performance en las primeras 6 horas de pronóstico, siendo este el período que es en donde se logra sacar el máximo provecho de sus potencialidades. Este método se divide en dos clases principales, que son los modelos de series temporales (ARIMA, predictores lineales, etc) y los de redes neuronales artificiales (multilayer perceptron, feedforward, etc). A diferencia de los métodos estadísticos de series temporales que son modelos lineales, las RNA's resuelven problemas de naturaleza no lineal, Haykin (2009), como por ejemplo, los pronósticos de energía eólica, Soman (2010). Las RNA's fueron desarrolladas buscando ser un modelo matemático con estructura similar a la del cerebro humano, modelos no lineales, los cuales trabajan en paralelo con múltiples conexiones, teniendo como elemento central las neuronas, Haykin (2009). Las principales clasificaciones de las RNA's son respecto al número de capas (monocapas o multicapas), tipos de conexiones (prealimentación (feed-forward en inglés), recurrentes/recursivas

(recurrent en inglés) o convolucionales (Deep Convolutional Neural Networks en inglés)) y respecto al aprendizaje (supervisado, no supervisado y reforzado). Se destaca el uso de las redes multicapa y entre los algoritmos de entrenamiento supervisado, la retropropagación (backpropagation), [Rumelhart \(1986a\)](#).

Las RNA se han utilizado principalmente para horizontes de muy corto plazo en la generación de potencia de parques eólicos [Varanasi \(2016\)](#) y velocidades de viento, [Ozgonenel \(2017\)](#), [Dumitri \(2017\)](#). Otra utilización de las RNA's, ha sido en los modelos denominados híbridos, donde se tiene una combinación de modelos físicos y modelos estadísticos, que buscan sacar provecho de los puntos fuertes de cada técnica. En la configuración de estos modelos híbridos, se usan las salidas de los modelos físicos (mesoescala o de circulación general de la atmósfera) como variables de entrada en los modelos de redes neuronales artificiales.

Para pronósticos con horizontes de tiempo de más de 6 horas hasta semanas, es necesario utilizar los modelos físicos, que son los modelos de circulación general y de mesoescala atmosférica, [Lange \(2005\)](#). Estos modelos tienen acopladas ecuaciones que describen los procesos físicos que ocurren en la atmósfera terrestre, los cuales se resuelven por métodos numéricos. Estas ecuaciones son aproximaciones matemáticas de los distintos procesos físicos que ocurren en la atmósfera. En los modelos numéricos de mesoescala se pueden tener distintos esquemas numéricos (parametrizaciones), [Pielke \(2013\)](#), [Stensurd \(2007\)](#).

Entre los modelos de mesoescala se destaca el "Weather Research and Forecasting" (WRF), [Skamarock \(2008\)](#), [NCAR \(2019\)](#), siendo este un modelo de software libre de código abierto, tiene el respaldo de la comunidad científica internacional. Verificaciones de pronósticos con el modelo WRF-ARW han sido realizadas en distintas regiones del mundo, como en la California Central en Estados Unidos, donde el modelo obtuvo buen desempeño para una región de terreno complejo pronosticando la velocidad del viento, [Clifford \(2011\)](#). El modelo WRF posee dos tipos de solvers dinámicos, que son el ARW (Advanced Research WRF, que es mantenido por NCAR's Mesoscale and Microscale Meteorology Laboratory, [NCAR \(2018\)](#)) y el NMM (Nonhydrostatic Mesoscale Model, desarrollado por el National Centers for Environmental Prediction, [NCEP \(2018\)](#)). El modelo WRF-ARW obtuvo altas correlaciones diarias y estacionales en la velocidad del viento en la región Noreste de Brasil [De Jong \(2017\)](#). Otros trabajos como [Stull \(2016\)](#), [Gutiérrez \(2018b\)](#), presentan el análisis de la capacidad del modelo WRF de simular la velocidad del viento a 100

metros de altura en función de la resolución horizontal de la grilla, para distintas parametrizaciones de capa límite. [Porrini \(2018\)](#) evaluó distintos esquemas numéricos de capa límite atmosférica del modelo WRF, a alturas sobre el nivel del suelo asociadas a la explotación de energía eólica. Haciendo una discriminación de los ciclos diarios, en casos de baja, media y alta velocidad de viento, por medio de un análisis cluster se concluyó que la mayoría de los esquemas mostraron una sobrestimación para velocidades bajas durante la noche, un buen desempeño durante el día, y una subestimación para altas velocidades medias en las primeras horas del día. Un modelo híbrido con el uso del WRF y RNA fue evaluado en pronósticos de 24 horas de horizonte de pronóstico en China, [Zhao \(2012\)](#), donde obtuvo buenos resultados.

Este trabajo presenta herramientas de pronóstico para la energía eólica en el corto plazo. Se hace uso del modelo numérico de mesoescala WRF-ARW, donde se sacan variables atmosféricas pronosticadas, como la velocidad media horaria del viento, dirección media horaria del viento y la densidad media horaria del aire. Dichas variables son dadas como entrada en técnicas de post-procesamiento basadas en regresiones lineales y redes neuronales artificiales. Al fin, se evalúa la potencia eléctrica pronosticada en un horizonte temporal de 24 horas, para un conjunto de 31 parques eólicos instalados en Uruguay, que sumados tiene un total de 1267,4 MW. La base de datos utilizada para el desarrollo del trabajo fue de dos años, con datos en intervalos horarios.

Capítulo 3

Energía Eólica

3.1. El Viento

La atmósfera terrestre es una capa gaseosa y de aerosoles que circunda la superficie del planeta Tierra y suele ser dividida en distintas capas de acuerdo a la distribución de temperatura en altura. En la atmósfera terrestre las capas desde la superficie terrestre hacia el espacio son: tropósfera, tropopausa, estratósfera, estratopausa, mesósfera, mesopausa, termósfera, termopausa y exósfera.

La capa más cercana a la superficie terrestre es la tropósfera, la cual se extiende hasta un promedio de altura de aproximadamente 11 Km en relación a la superficie terrestre. Dicha capa es caracterizada por un gradiente de temperatura negativo de $-6.5^{\circ}\text{C}/\text{Km}$ y una velocidad del viento que crece con la altura. La tropósfera suele ser dividida en dos subcapas: la atmósfera libre y la capa límite atmosférica, [Stull \(1988\)](#).

La atmósfera libre se caracteriza por ser la capa que está por encima de la capa límite atmosférica y es donde el movimiento del aire no está directamente afectado por los forzantes de la superficie terrestre. La atmósfera libre en general suele estar comprendida entre 3 Km y 11 Km de altura de la superficie terrestre, dependiendo su extensión de las condiciones atmosféricas. A su vez, la capa límite atmosférica es la capa que abriga la gran mayoría de la vida terrestre, y suele estar comprendida desde la superficie hasta un valor máximo de 3 Km de altura, siendo que este límite superior varía según las condiciones atmosféricas. [Stull \(1988\)](#) define la capa límite atmosférica como “*la parte de la tropósfera que es directamente influenciada por la presencia de la superficie*”

terrestre, y responde a los forzantes de la superficie a una escala de tiempo de aproximadamente una hora o menos”. Stull (1988) agrega que los forzantes incluyen la fricción, evaporación y evapotranspiración, transferencia de calor, emisión de contaminantes y modificación de flujo inducido por la superficie.

El viento atmosférico surge a partir del calentamiento desigual que sufren las distintas regiones de la tierra, lo cual es resultante de la radiación solar incidente, que a su vez causa distintos campos de presiones debido a este calentamiento desigual. Zonas con mayor calentamiento suelen tener menor presión atmosférica, lo que hace que una masa de aire proveniente de estas regiones suba para la parte superior de la atmósfera debido a su menor densidad, y estas suelen caer en las regiones más frías. A su vez, en las zonas más frías el aire tiene mayor densidad y se mueven en dirección a las regiones en que las parcelas de aire caliente subieron. Esta dinámica, sumada al movimiento de las fuerzas centrífugas y de Coriolis, debido a la rotación de la tierra forman los vientos a escala global, Custódio (2013).

El viento, así como otras variables atmosféricas tienen asociados distintas escalas de tiempo y fenómenos asociados. La figura 3.1, presenta el resultado de medición de las fluctuaciones de la velocidad del viento, realizado por Hoven (1956).

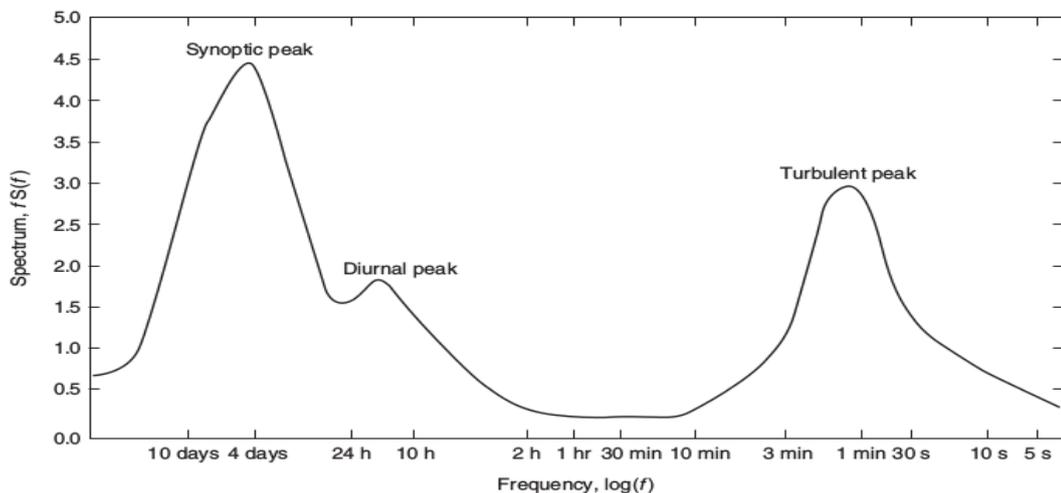


Figura 3.1: Espectro de la velocidad del viento, realizado por Hoven (1956) en base a mediciones de las fluctuaciones de la velocidad del viento. Fuente: adaptado de Ackermann (2005).

El pico de turbulencia es causado principalmente por ráfagas de viento en rangos menores a segundos hasta un rango algunos minutos. El pico diario depende de la variación diaria de la velocidad del viento, como por ejemplo

las brisas marinas que son causadas por la diferencia de temperatura entre la superficie terrestre y el mar. A su vez el pico sinóptico depende del cambio de patrones del tiempo, que típicamente varían de intervalos diarios a semanales.

De la perspectiva de la generación de energía eólica, el pico de turbulencia puede afectar la calidad de energía generada, la cual depende mucho de la tecnología de turbina utilizada, las cuales pueden absorber gran parte de las fluctuaciones y generar una salida de potencia suave en sistemas altamente acoplados a la red [Ackermann \(2005\)](#). Los picos sinópticos y diarios de la velocidad del viento son de alto interés para las planificaciones en los sistemas eléctricos que tienen un alto porcentaje de energía eólica instalada. De acuerdo a la figura 3.1, se percibe que tanto los datos diezminutales como los datos a escala horaria (máximo 2 horas) tienen los promedios semejantes, visto que están en el mismo intervalo.

Los eventos meteorológicos son divididos en tres escalas principales, las cuales clasifican cada tipo de evento según sus dimensiones espaciales y escalas de tiempo de duración. Dichas escalas son denominadas de macro-escala, meso-escala y micro-escala meteorológicas. La figura 3.2 presenta la clasificación de dichas escalas meteorológicas, que son propuestas por dos trabajos, el de [Orlanski \(1975\)](#) y el de [Fujita \(1981\)](#).

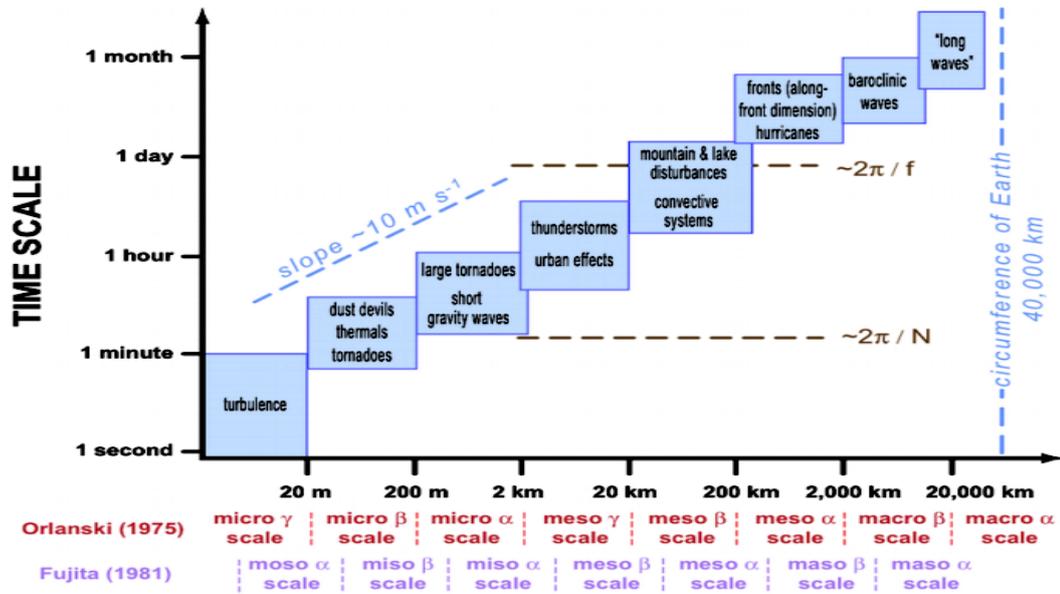


Figura 3.2: Clasificación de las escalas meteorológicas según [Orlanski \(1975\)](#) y [Fujita \(1981\)](#). Fuente: [Markowski \(2010\)](#).

El viento en la capa límite atmosférica, suele estar afectado por los forzantes

de la superficie terrestre, [Stull \(1988\)](#). Esta influencia de los forzante de la superficie hace que la velocidad del viento en la capa límite atmosférica tenga un comportamiento característico, que crece con la altura.

Se define el perfil logarítmico ($d\theta/dZ = 0$, siendo θ la temperatura potencial) y la velocidad del viento (“V” (m/s)) en una altura “h” de la superficie puede ser calculada a partir de la ecuación [3.1](#).

$$V = \frac{u^*}{k} \ln \frac{h}{z_o} \quad (3.1)$$

En la ecuación [3.1](#) u^* representa la velocidad de fricción (m/s) del viento con la superficie terrestre, k es la constante de Von Karman y se le asigna un valor de 0.4, “h” es la altura de interés (m) y z_o es la longitud de rugosidad del sitio (m), y representa la aerodinámica de la superficie.

En la capa límite atmosférica las condiciones están divididas en la mayoría del tiempo entre la atmósfera inestable y estable. Una de las diferencias más significativas en ambas condiciones atmosféricas, es en cuanto a la intensidad de turbulencia. Se define la intensidad de turbulencia (IT) según [3.2](#).

$$IT = \frac{\sigma_x}{V} \quad (3.2)$$

En la ecuación [3.2](#), σ_x representa la desviación estándar de la velocidad del viento (m/s) y V la velocidad media del viento (m/s). En la capa límite atmosférica, la intensidad de turbulencia suele ser mayor cuanto más rugoso sea el terreno y más cercano de la superficie sea la altura de la velocidad. [Kaimal \(1994\)](#) describe el proceso de producción de turbulencia de origen térmico, a través de los vórtices térmicos producidos con el calentamiento de la superficie por la radiación incidente del sol, siendo determinante el intercambio de calor con la superficie terrestre. La norma [61400-1 \(2005\)](#) clasifica para determinados umbrales de IT, las clases de aerogeneradores más adecuados para determinado umbral de IT.

La atmósfera en condiciones inestables normalmente se da durante el período diurno, donde la superficie recibe la radiación solar incidente y se calienta. A su vez, la atmósfera próxima recibe el calor de la superficie, haciendo

con que el flujo de aire en esta región tenga una mezcla mayor, debido a los vórtices térmicos generados. Estos vórtices térmicos a su vez, generan un mayor nivel de turbulencia del viento. En una atmósfera inestable el gradiente de temperatura es negativo, debido a que cuando crece la altura, disminuye la temperatura del aire. La atmósfera estable normalmente se da durante el período nocturno, donde la superficie está más fría en relación al aire de la atmósfera próxima, siendo así que el calor sensible es transferido de la atmósfera terrestre hacia la superficie. En estas condiciones el proceso de mezcla térmica es pequeño, y la turbulencia disminuye considerablemente en la capa límite atmosférica. En una atmósfera estable el gradiente de temperatura es positivo, debido a que cuando crece la altura se aumenta la temperatura del aire. De acuerdo a [Moraes \(2004\)](#), la estabilidad de la atmósfera puede ser definida de acuerdo a su capacidad de resistir o intensificar los movimientos verticales. Cuando hay una resistencia a los movimientos verticales se suele denominar atmósfera estable, con una intensificación de los movimientos verticales, la atmósfera se suele denominar inestable o convectiva, y cuando es indiferente a cualquier tipo de movimiento vertical se suele denominar atmósfera neutra.

[De Almeida \(2016\)](#), caracterizó estadísticamente el ciclo diario en los cien primeros metros de la capa límite atmosférica, a partir de datos medidos en Uruguay. La figura 3.3 presenta la velocidad horaria media del viento a distintas alturas, con sus desviaciones estándar, para un día despejado, el gradiente de temperatura en altura en base a temperaturas a 100.8 y 3.4 metros de la superficie, y la radiación solar incidente a nivel de superficie.

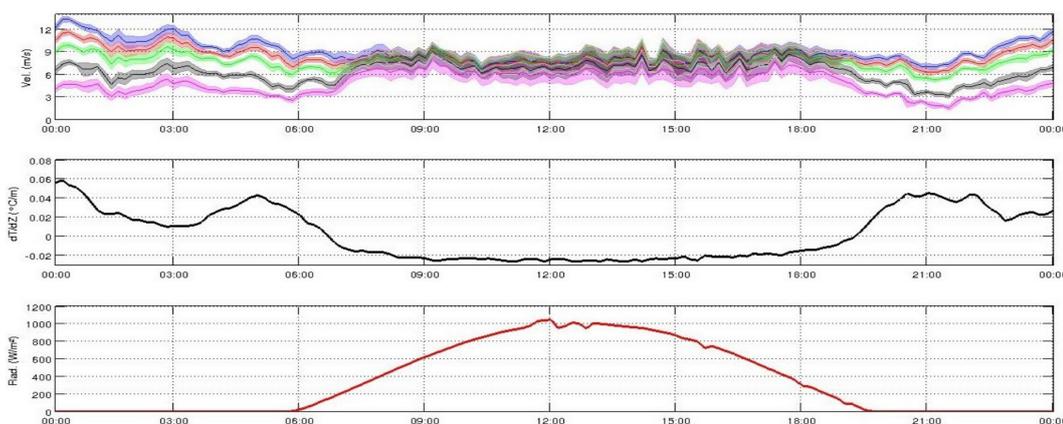


Figura 3.3: Perfil del viento (fig. superior) con velocidad media y desviación estándar (sombreado) las alturas 101.8 m (azul), 81.8 m (rojo), 60.8 m (verde), 25.7 m (negro) y 10.1 m (magenta), gradiente de temperatura (fig. central) y radiación solar incidente (fig. inferior).

En base a la figura 3.3, se percibe que en condiciones de atmósfera estable hay una menor desviación estándar de la velocidad media del viento, lo que implica una menor intensidad de turbulencia. Durante los momentos posteriores a la salida del sol, se da una condición de atmósfera inestable, en la cual se verifica, una disminución relativa de la velocidad media del viento en las capas más altas y un aumento de velocidad en las capas más bajas. Esto hace con que en estas condiciones de atmósfera, la velocidad media del viento sea muy parecida en distintas alturas de la capa límite atmosférica.

Además del comportamiento del viento durante el ciclo diario, los cambios se dan también a nivel estacional. En Uruguay, según Cornalino (2015) el comportamiento estacional a lo largo del año es bastante uniforme en todo el territorio, con diferencias muy pequeñas sobre todo en la región atlántica. Entre tanto, Cornalino (2015) hace énfasis en que *“hay una leve diferencia entre las estaciones de la costa y de las de tierra adentro, caracterizada sobre todo por velocidades levemente superiores durante el invierno en estas últimas”*. En su trabajo, Cornalino (2015) también destaca que la variación interanual del recurso es baja, y suele estar entre un 2% y un 5% respecto de la media histórica.

En líneas generales, en base a lo expuesto sobre el comportamiento del viento en la capa límite atmosférica, se puede destacar características relevantes respecto a la variabilidad del ciclo diario y anual. Las turbinas eólicas extraen la energía cinética del viento, cuya mayor producción se da en los períodos de estabilidad atmosférica (noche).

El comportamiento estacional muestra que en Uruguay hay una mayor producción de energía eólica durante el invierno, donde hay un leve aumento de velocidad del viento en ubicaciones tierra adentro, comparadas a otras estaciones del año, de acuerdo a lo expuesto por Cornalino (2015).

3.2. Energía Eólica

La energía en movimiento es generada a partir del aprovechamiento de la energía cinética del aire, o sea, del viento. Más específicamente, esta energía es aprovechada a partir del flujo de energía cinética que atraviesa el área de barrido de las palas de un aerogenerador.

Considerando una partícula de aire ubicada en el punto (x,y,z) del espacio que tiene una velocidad V asociada al instante t , $(\vec{V}(x,y,z,t) = (v,u,w))$, siendo

”v“ la componente horizontal de la velocidad del viento, que es normal (”n“) al area de barrida de palas del aerogenerador (”A“), el flujo da la energía cinética del aire aprovechada por un aerogenerador es presentada por la figura 3.4.

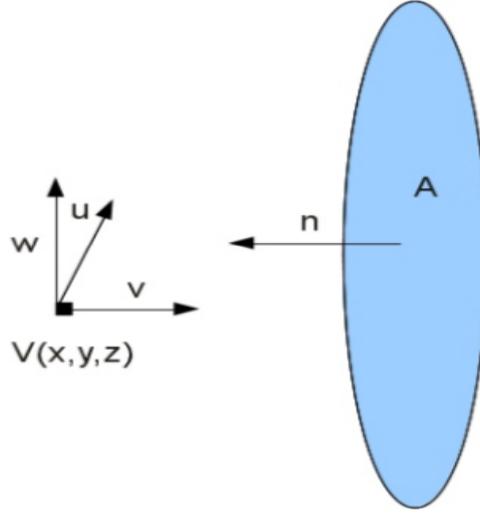


Figura 3.4: Flujo de energía cinética del viento que atraviesa el área de barrido de las palas de un aerogenerador. Fuente: [Gutiérrez \(2011\)](#).

La ecuación 3.3 presenta el cálculo de la potencia del viento que atraviesa el area de barrido de palas de un aerogenerador A, donde la variable ρ representa la densidad del aire (kg/m^3).

$$P = \int_A \frac{1}{2} \rho v^2 (\vec{V} \vec{n}) dA \quad (3.3)$$

A su vez, la energía eólica extraída del viento, asociada a un periodo de tiempo Δt es presentada por la ecuación 3.4.

$$E = \int_{\Delta t} \int_A \frac{1}{2} \rho v^2 (\vec{V} \vec{n}) dA dt \quad (3.4)$$

En base a las ecuaciones 3.3 y 3.4, la ecuación 3.5 presenta la potencia eólica media disponible en un período de tiempo Δt .

$$P_m = \frac{1}{2} \rho A \langle \bar{v}^3 \rangle \quad (3.5)$$

En la ecuación 3.5, la variable $\langle \bar{v}^3 \rangle$ representa un valor medio en términos espaciales y temporal asociado al área de barrido de palas (A).

Los aerogeneradores suelen ser divididos en dos tipos principales, que son los de eje vertical y los de eje horizontal. Los aerogeneradores de eje vertical son más utilizados en la microgeneración y normalmente están instalados cerca del suelo, los de tipo Darrieus (Darrieus (1931)), Savonius (Savonius (1931), Zemamou (2017)). Para este trabajo, se estudian los aerogeneradores de eje horizontal, los cuales son largamente utilizados en la eólica de gran escala a nivel mundial y generan energía eólica a partir de alturas entre 65 metros y 120 metros aproximadamente, siendo conocidos como modelo Danés. La figura 3.5 muestra un aerogenerador de eje vertical del tipo Darrieus y un aerogenerador del tipo eje horizontal, con la posición de las principales partes de los aerogeneradores.

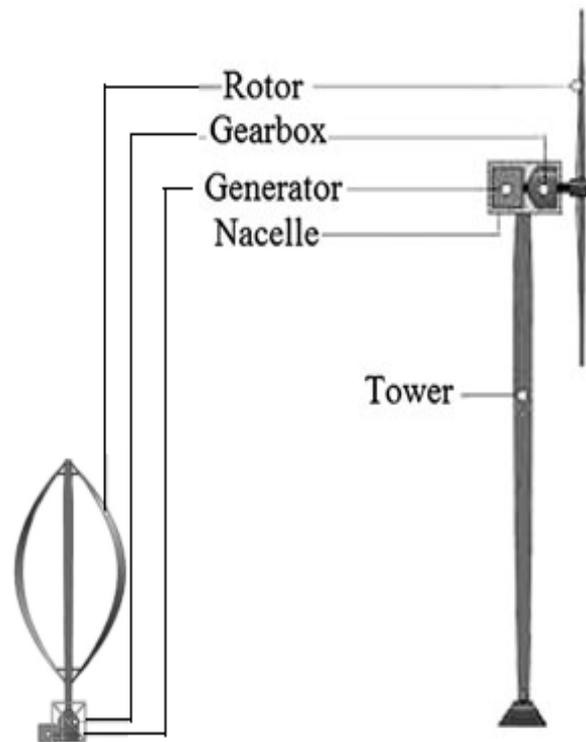


Figura 3.5: Aerogeneradores de eje vertical del tipo Darrieus (izquierda) y de eje horizontal (derecha).

La figura 3.5 indica los principales componentes de los aerogeneradores, siendo que el rotor, la caja multiplicadora y el generador eléctrico son comu-

nes tanto a los aerogeneradores de eje vertical como a los de eje horizontal. A su vez, la torre es utilizada solamente en los modelos de eje horizontal. De manera resumida, en un aerogenerador de eje horizontal, que es el modelo utilizado en los parques eólicos estudiados en este trabajo, la generación de energía eléctrica se da de la siguiente manera.

- Transformación de la energía cinética del viento en energía mecánica (viento hace girar las palas del aerogenerador, que a su vez gira el eje principal de la turbina eólica).
- El eje de la turbina gira, y pasando por una caja multiplicadora, el valor de rotación del eje en rpm (rotaciones por minutos) es multiplicado por "x" veces el valor inicial.
- El eje en alta rotación, acciona el generador eléctrico, que a su vez transforma la energía mecánica del eje en energía eléctrica.

Para definir la energía aprovechable del viento para la generación de energía se suele utilizar el coeficiente de potencia. Se define el coeficiente de potencia (C_p) de una turbina eólica la relación entre la potencia total extraída del viento (P_t) y la potencia media disponible del viento (P_m). La ecuación 3.6, presenta el cálculo de dicho coeficiente.

$$C_p = \frac{P_t}{\frac{1}{2}\rho A v^3} \quad (3.6)$$

En energía eólica, hay un máximo aprovechable de la energía del viento, siendo esto denominado límite de Betz. El límite de Betz establece que cualquier sistema de aprovechamiento del recurso eólico puede transformar como máximo un 59% de la potencia media del viento. Según esta teoría, la potencia teórica máxima que puede ser extraída del viento, es presentada por la ecuación 3.7.

$$P_m = \frac{1}{2}\rho A \langle v^3 \rangle C_p = \frac{1}{2}\rho A \langle v^3 \rangle \cdot 0.59 \quad (3.7)$$

De este modo, incluso si fuera posible extraer la energía del viento sin pérdidas mecánicas o eléctricas, solo un 59% de la energía del viento podría ser utilizada por un aerogenerador, [Gash \(2012\)](#).

Una característica muy importante de los aerogeneradores son las curvas de potencia, que son características para cada modelo. Las curvas de potencia, muestran la relación entre la velocidad media del viento y la generación de energía eléctrica (kW), para todo el rango de velocidades del viento en que puede operar el aerogenerador. La figura 3.6, presenta una curva de potencia de ejemplo, siendo esta para un aerogenerador de potencia 1500 kW (1.5 MW).

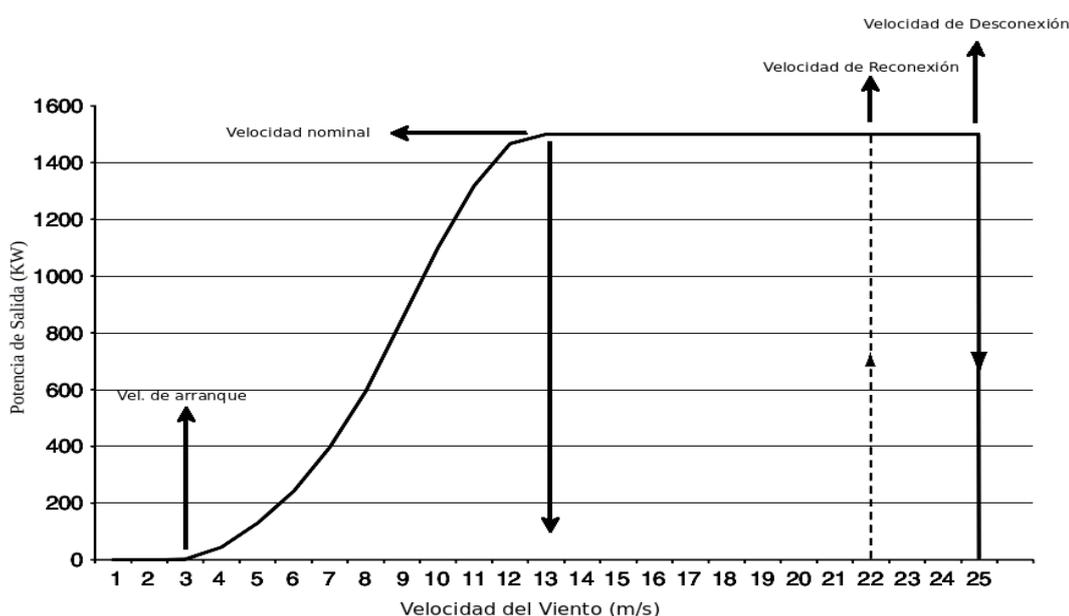


Figura 3.6: Curva típica de un aerogenerador de 1.5 MW de potencia. Fuente: [Ackermann \(2005\)](#).

En base a la figura 3.6, es posible identificar distintas regiones de la curva de potencia.

- $0 \text{ m/s} \leq x < 3 \text{ m/s}$ - En este rango de velocidad del viento, el aerogenerador no produce energía, debido a la baja velocidad del viento.

- Velocidad de arranque: En el modelo genérico de aerogenerador presentado en la figura 3.6, a partir de 3 m/s empieza la generación de energía eléctrica, siendo este valor denominado la velocidad de arranque, conexión o entrada (cut-in, del inglés). De 3 m/s hasta 13 m/s la curva sigue una rampa,

que es proporcional a la velocidad del viento al cubo.

- Potencia nominal - Con valores de $13 \text{ m/s} \leq x < 25 \text{ m/s}$, el aerogenerador trabaja con la potencia nominal, o sea, el aerogenerador produce la energía máxima, lo máximo que puede generar de energía eléctrica.

- Velocidad de desconexión - A partir de 25 m/s el aerogenerador sale de servicio y deja de producir energía, para evitar posibles daños en las turbinas o sus alrededores, siendo esta velocidad de 25 m/s , denominada de velocidad de desconexión, corte (cut-out). Hasta que la velocidad del viento no se sitúe por debajo del valor de la velocidad de desconexión, el aerogenerador deja de producir energía.

- Velocidad de reconexión - El sistema de reconexión de un aerogenerador depende del modelo de control de potencia utilizado, siendo este parámetro entre los presentados en la figura 3.6, es el que más puede variar entre los distintos modelos de aerogeneradores. En la curva de potencia presentada en la figura 3.6, para que el aerogenerador vuelva a generar, después de una bajada de la velocidad del viento, el sistema utiliza un margen de velocidad del viento para la reconexión. En la figura 3.6, la velocidad de reconexión está ubicada en 22 m/s (línea punteada), siendo esta la velocidad máxima permitida para que el aerogenerador vuelva a generar energía, post período de entrada en condición de “fuera de servicio” por cut-out.

En energía eólica, el análisis de la curva de potencia, con sus respectivos valores de generación de electricidad para distintos rangos de velocidad del viento, a distintas alturas de la superficie (altura del buje), es clave para el desarrollo de un buen proyecto de parque eólico. En base a un histórico de mediciones de variables meteorológicas (velocidad del viento, temperatura del aire, presión atmosférica), en una ubicación donde se desea instalar un parque eólico, a las mismas alturas de la superficie que se pretenda instalar un aerogenerador (tomando como base la altura del buje) y en base a una distribución de probabilidad del viento, como la distribución de Weibull, [Bowdwn \(1983\)](#), basada en periodo mínimo aceptable para el desarrollo de un proyecto de energía eólica, se puede elegir el modelo más apropiado para la instalación de un parque eólico en determinado lugar.

En energía eólica, la Norma IEC 61400-12-1 establece los requerimientos

para la validación de mediciones de viento con fines de generación de energía eléctrica producidas por turbinas eólicas. Dicha norma establece criterios como por ejemplo, que las mediciones de la velocidad del viento sean realizadas en la misma altura del eje de giro del rotor del aerogenerador. Dicha norma tiene en cuenta las condiciones y las influencias del filtrado de datos de velocidad del viento, análisis de rendimiento de la potencia de aerogeneradores por la potencia medida y la curva de potencia y la producción anual de energía estimada. Otro punto importante que discute la Norma IEC 61400-12-1 es la caracterización de las principales variables meteorológicas que tienen influencia en la generación de energía eléctrica, como la velocidad y dirección media del viento, así como la densidad del aire.

Una característica importante de la implementación de la energía eólica en larga escala en un sistema eléctrico es el efecto de suavizar la variabilidad de potencia producida. La figura 3.7 presenta el efecto de suavizamiento de potencia con el incremento del número de turbinas eólicas en un sistema eléctrico.

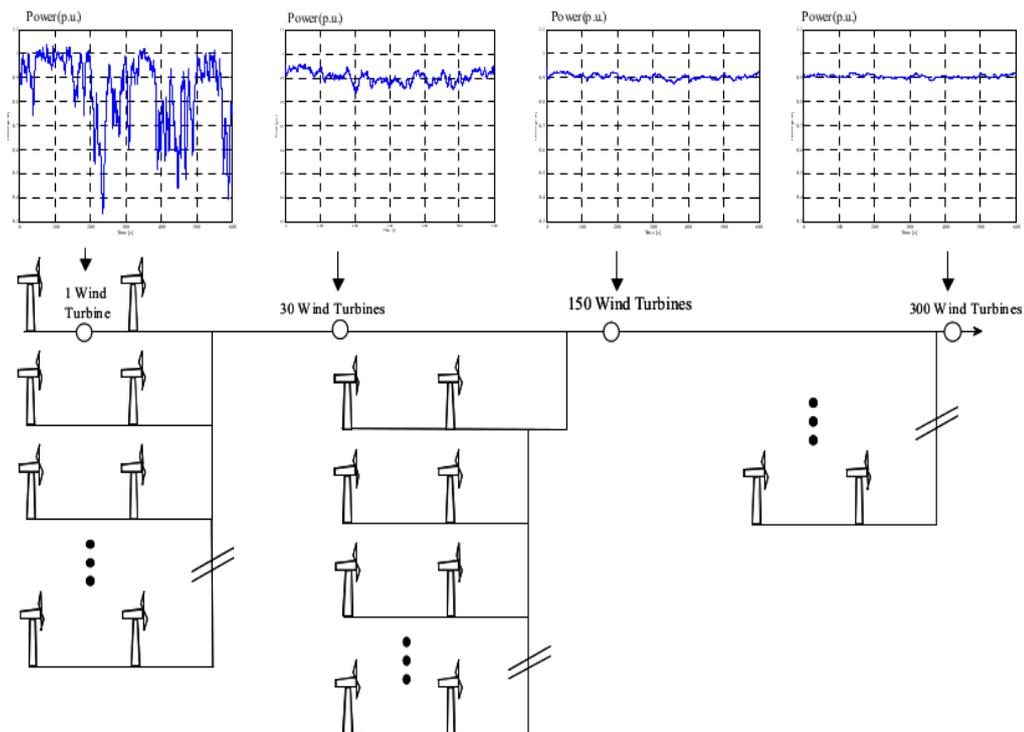


Figura 3.7: Efecto de suavizamiento de potencia en parques eólicos con el incremento de turbinas eólicas. Fuente: Rosas (2004).

De acuerdo a Ackermann (2005), agregar energía eólica a un sistema eléctrico

co promueve efectos positivos para la operación y calidad de potencia en un sistema eléctrico. En cuanto al tema de operación del sistema eléctrico, [Ackermann \(2005\)](#) destaca dos motivos: el efecto del incremento del número de turbinas eólicas en el sistema, conforme destacado también por [Rosas \(2004\)](#), y la distribución geográfica de los parques eólicos. [Ackermann \(2005\)](#) destaca que bajo condiciones ideales, la variación porcentual en la potencia de salida cae a $n^{1/2}$, donde “n” es el número de turbinas, siendo así que cuanto mayor sea el valor de “n”, menor será la variación en la potencia de salida, lo que acaba por reducir el impacto de los picos de turbulencia. A su vez, el efecto de la distribución geográfica reduce el impacto de patrones climáticos que puedan afectar a todos los aerogeneradores al mismo tiempo, como por ejemplo, los eventos de rampa producidos por ráfagas de viento.

Capítulo 4

Sistema Eléctrico en Uruguay

El sistema eléctrico en Uruguay está compuesto por cinco distintas fuentes de energía, que son la hidráulica, térmica/fósil, biomasa, fotovoltaica y la eólica. En la matriz eléctrica, el 84.89% de la potencia instalada está asociada a fuentes de origen renovable y el 15.11% a fuentes de origen no renovable.

La generación de energía eléctrica a partir de centrales hidroeléctricas está basada en el uso de cuatro represas, las cuales están instaladas en el Río Negro (centrales hidroeléctricas Constitución, Dr. Gabriel Terra y Rincón de Baygorria) y en el Río Uruguay (Salto Grande). La tabla 4.1 presenta la potencia instalada y el agente generador en cada central hidroeléctrica de Uruguay.

Tabla 4.1: Potencia instalada y agente generador en cada central hidroeléctrica de Uruguay. Fuente: UTE (2019).

Generador	Agente Generador	Pot. Instalada (MW)
Constitución	UTE	333
Dr. Gabriel Terra	UTE	152
Rincón de Baygorria	UTE	108
Salto Grande	CTM	945
TOTAL		1538

Las hidroeléctricas ubicadas en el Río Negro son de propiedad de la empresa eléctrica estatal UTE, y la hidroeléctrica de Salto Grande es de propiedad de la CTM (Comisión Técnica Mixta), la cual es una comisión binacional compuesta por Uruguay y Argentina, siendo Salto Grande una represa hidroeléctrica binacional.

La hidroeléctrica Dr. Gabriel Terra (Rincón del Bonete) fue inaugurada en 1945 y se caracteriza por tener el mayor embalse entre todas las represas del

país, con una reserva para aproximadamente 135 días UTE-DPE (2013). La represa de Baygorria fue inaugurada en 1960 (reserva para 2.8 días), Constitución (Palmar) en 1982 (reserva para 8 días) y Salto Grande en 1979 (reserva para 10 días). La figura 4.1 presenta la ubicación de las cuatro hidroeléctricas del país. En el centro del país se puede observar en el sentido norte-sur las represas Dr. Gabriel Terra, Rincón de Baygorria y Constitución respectivamente. Al norte del país, en la frontera con Argentina se puede observar la ubicación de la represa hidroeléctrica binacional de Salto Grande.

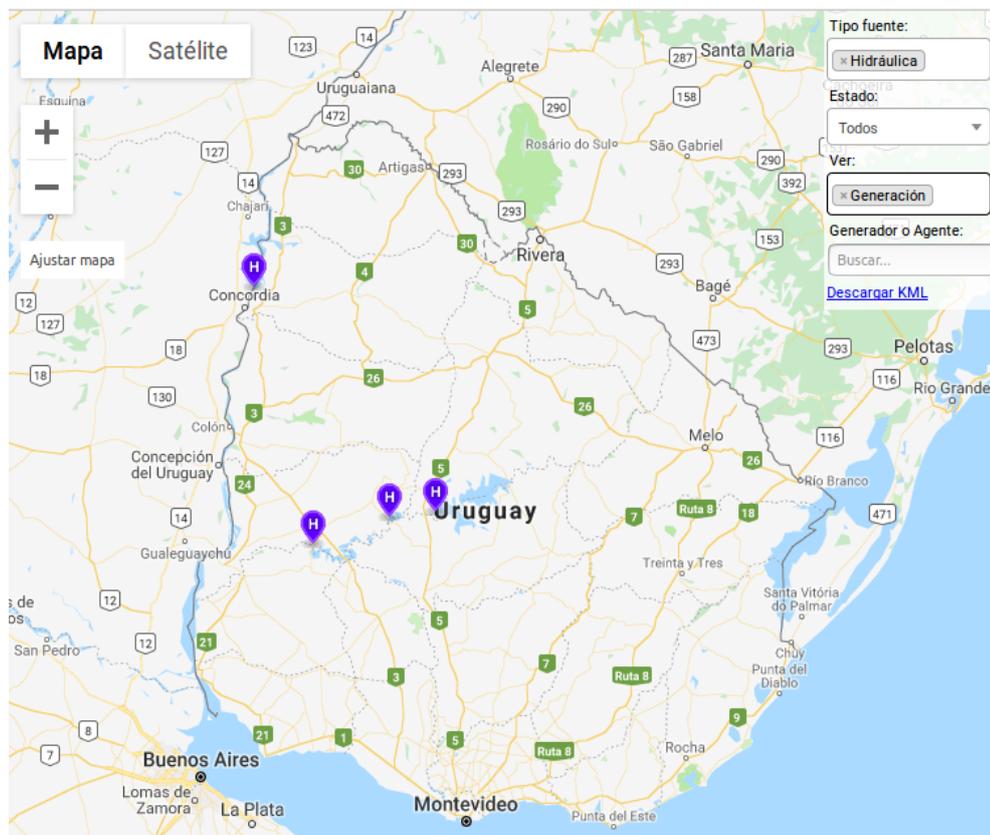


Figura 4.1: Ubicación de las hidroeléctricas en Uruguay. Fuente: UTE (2019).

Las centrales térmicas del país utilizan fuel oil, gas natural y carbón como combustible. Actualmente hay un total diez centrales térmicas en Uruguay, donde nueve están en servicio y una (Punta del Tigre B) está en período de pruebas. Punta del Tigre B cuando entre en funcionamiento, será la central térmica con mayor potencia instalada en Uruguay. Todas las centrales térmicas sumadas, representan el 15.11% de la potencia instalada total en la matriz eléctrica de Uruguay. La tabla 4.2 presenta la potencia instalada en cada central térmica ubicada en territorio Uruguayo.

Tabla 4.2: Potencia instalada y agente generador en cada central térmica/fósil de Uruguay. Fuente: UTE (2019).

Generador	Agente Generador	Pot. Instalada (MW)
Cerros de Vera	UTE	0.08
CTR	UTE	212
Motores Central Batlle	UTE	80
Pueblo Fernández	UTE	0.23
Punta del Tigre 7 y 8	UTE	50
Punta del Tigre A	UTE	300
Punta del Tigre B	UTE (EN PRUEBAS)	360
San Gregorio	UTE	1.44
Turbina Río Branco	UTE	4.3
Zendaleather	Zendaleather S.A.	3.72
TOTAL		651.77

El 90 % de las centrales térmicas tienen como agente generador la empresa eléctrica estatal UTE (excepto Zendaleatherl). La mayoría de las centrales están ubicadas en el sur del país (región más densamente poblada del país). La ubicación geográfica de las usinas térmicas es presentada en la figura 4.2.

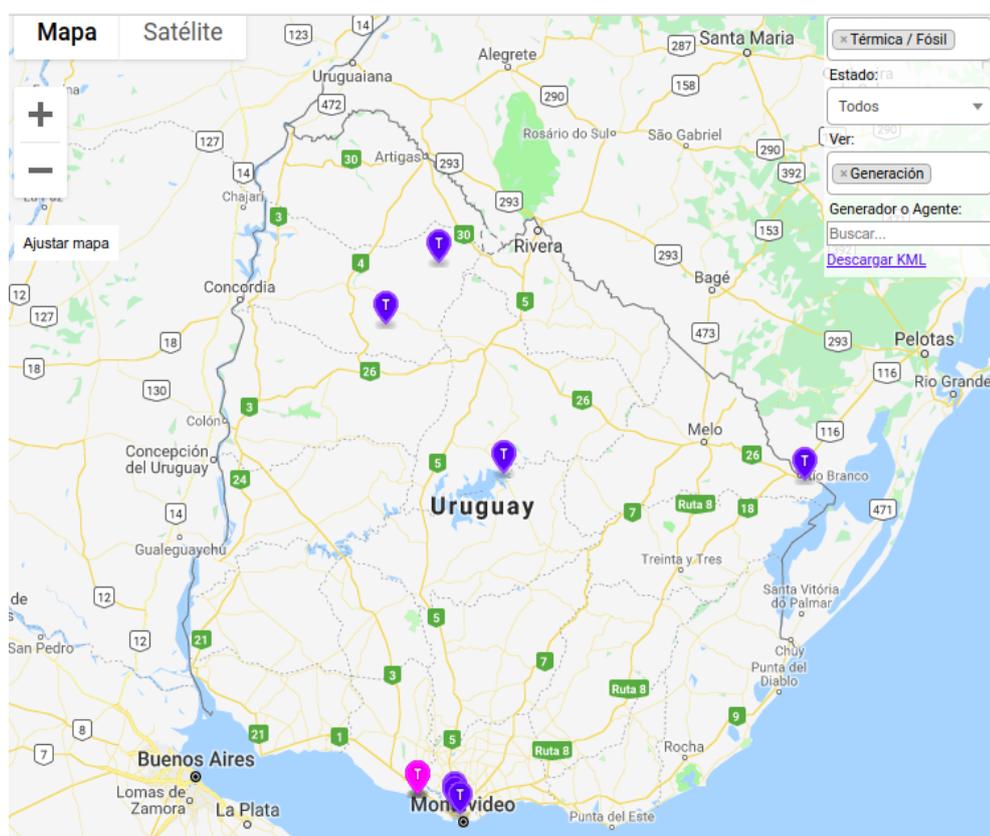


Figura 4.2: Ubicación de las térmicas/fósiles de Uruguay. Fuente: UTE (2019).

Las centrales de biomasa en Uruguay utilizan materia orgánica, como residuos industriales, básicamente provenientes de la industria forestal y del arroz. La tabla 4.3 presenta la potencia instalada en cada central.

Tabla 4.3: Pot. inst. y agente gen. de las centrales de biomasa. Fuente: UTE (2019).

Generador	Agente Generador	Pot. Inst. (MW)
Alur	Alcoholes del Uruguay S.A.	10
Arboreto	Lanas Trinidad S.A. E	0.6
Bioener	Bioener S.A.	12
Fenirol	Fenirol S.A.	10
Galofer	Galofer S.A.	14
Las Rosas	Intendencia de Maldonado	1.2
Liderdat	Liderdat S.A.	5
Montes del Plata	Celulosa y Energía Punta Pereira S.A.	180
Ponlar	Ponlar S.A.	7.5
UPM	UPM	161
Uruply	Uruply S.A.	12
TOTAL		413.3

La figura 4.3 presenta la ubicación geográfica de las centrales de biomasa.

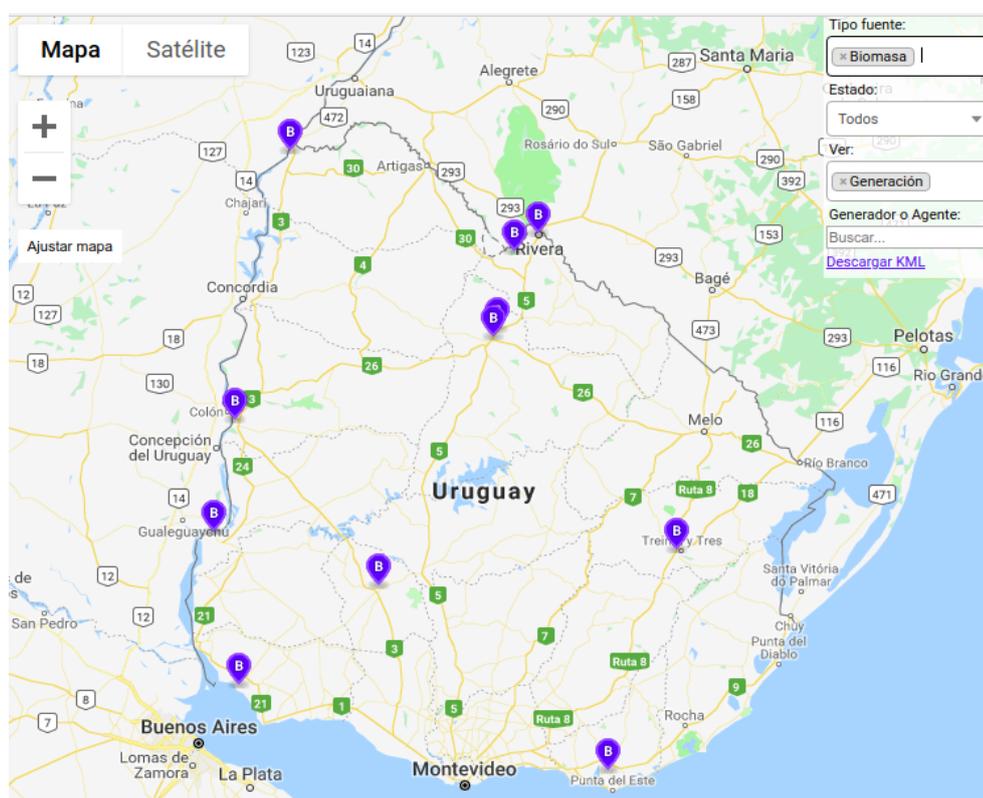


Figura 4.3: Ubicación de las centrales de biomasa. Fuente: UTE (2019).

Las plantas fotovoltaicas presentes en Uruguay están ubicadas en el Norte y Noroeste del país, regiones estas con mayor potencial de energía solar según el mapa solar, [LES \(2017\)](#), [Alonso \(2017\)](#). La mayoría de las plantas fotovoltaicas tienen como agente generador, empresas privadas. La tabla 4.4 presenta la potencia instalada en cada planta fotovoltaica.

Tabla 4.4: Potencia instalada y agente generador de las plantas fotovoltaicas en Uruguay. Fuente: [UTE \(2019\)](#).

Generador	Agente Generador	Potencia Instalada (MW)
Abril	Gilpyn S.A.	1
Alto Cielo	Alto Cielo S.A. E	20
Arapey Solar	Giacote S.A.	10
Asahi	MIEM-UTE	0.5
Casalko	Casalko S.A.	1.76
Cerros de Vera Solar	UTE	0.05
Del Litoral	Jolipark S.A.	16
Dicano	Dicano S.A.	11.25
El Naranjal	Colidim S.A.	50
Fenima	Fenima S.A.	9.5
La Jacinta	Jacinta Solar Farm S.R.L.	50
Menafra Solar	Giacote S.A.	20
Natelu	Natelu S.A.	9.5
Petilcoran	Petilcoran S.A.	9.5
Raditon	Raditon S.A.	8
TS	Cernal S.A.	1
Vingano	Vingano S.A.	1
Yarnel	Yarnel S.A.	9.5
TOTAL		228.56

En Uruguay los esfuerzos se han concentrado en la investigación del recurso solar, el desarrollo de la energía solar térmica para el calentamiento de agua y la energía solar fotovoltaica para generar energía eléctrica, [MIEM \(2019\)](#). Las instalaciones de energía solar fotovoltaica en Uruguay han tenido un crecimiento en los últimos años, tanto a pequeña escala como a gran escala, cuando se pasó a tener 0 MW en el año 2012 a contar con los actuales 228.56 MW instalados para la generación conectada a la red, y 245.31 MW considerando la microgeneración, generación sin inyección a la red y proyectos de gran escala conectados a la red.

De acuerdo a [MIEM \(2019\)](#), en Uruguay se destacan tres tipos de emprendimientos en energía solar, que son: a) microgeneración: instalaciones en baja tensión hasta un máximo de 150 kW, b) generación sin inyección a la red, sin

límite de potencia, y c) proyectos de generación fotovoltaica de gran escala. La figura 4.4 presenta la ubicación geográfica de las plantas fotovoltaicas.

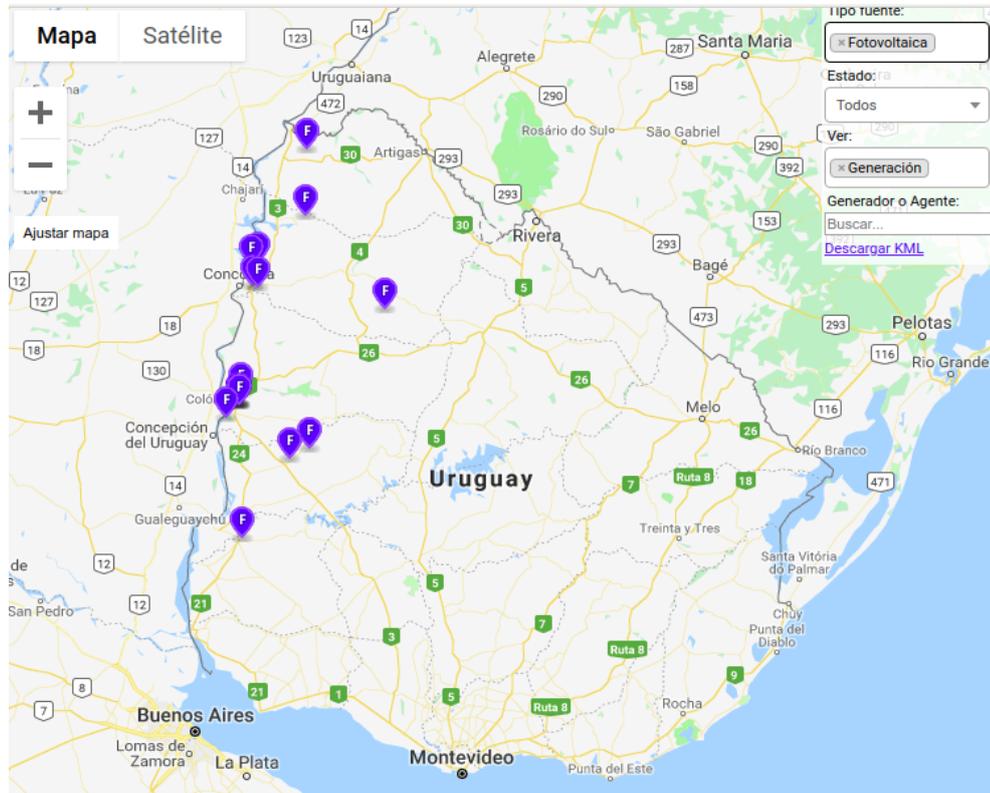


Figura 4.4: Ubicación de las plantas fotovoltaicas. UTE (2019).

A su vez, la energía eólica fue la fuente de energía renovable que más creció en los últimos años en Uruguay. Los principales estudios sobre la variabilidad del recurso eólico a lo largo del territorio Uruguayo, y la viabilidad de implantación, se hicieron en la Facultad de Ingeniería (FING), Universidad de la República (UdelaR). A partir del estudio del recurso eólico, surge en el año 2009, a través de un convenio con el Programa de Energía Eólica de Uruguay (PEEU), el mapa eólico de Uruguay, MIEM (2009), lo cual presenta el recurso eólico disponible en todo el territorio a distintas alturas de la superficie. Según el mapa eólico, la región con mayor disponibilidad de recurso eólico en Uruguay es el sur del país.

Los tipos de parques eólicos instalados en territorio nacional son básicamente tres: los auto productores, los parques para el mercado spot y los parques eólicos de gran escala. Los parques auto productores tienen como característica consumir una parte de la potencia generada, de modo a suministrar su demanda, y el excedente, es inyectado en la red. A su vez los parques eólicos

del mercado spot, la energía es negociada con UTE, y se la entrega cuando la energía contratada por el ente no alcanza la demanda. La energía de los parques del mercado spot se entrega al precio de mercado del momento de la compra/venta y no a un precio de contrato preestablecido. Debido a la alta incorporación de parques eólicos con contratos de compra/venta, los parques del mercado spot han tenido poca venta de energía en los últimos años. Los parques eólicos que suministran energía a la red tienen contratos con precios fijados, normalmente con un plazo de 20 años, y es establecida la entrega de la energía generada en el sistema interconectado nacional (SIN). La figura 4.5 presenta la ubicación geográfica de los parques eólicos.

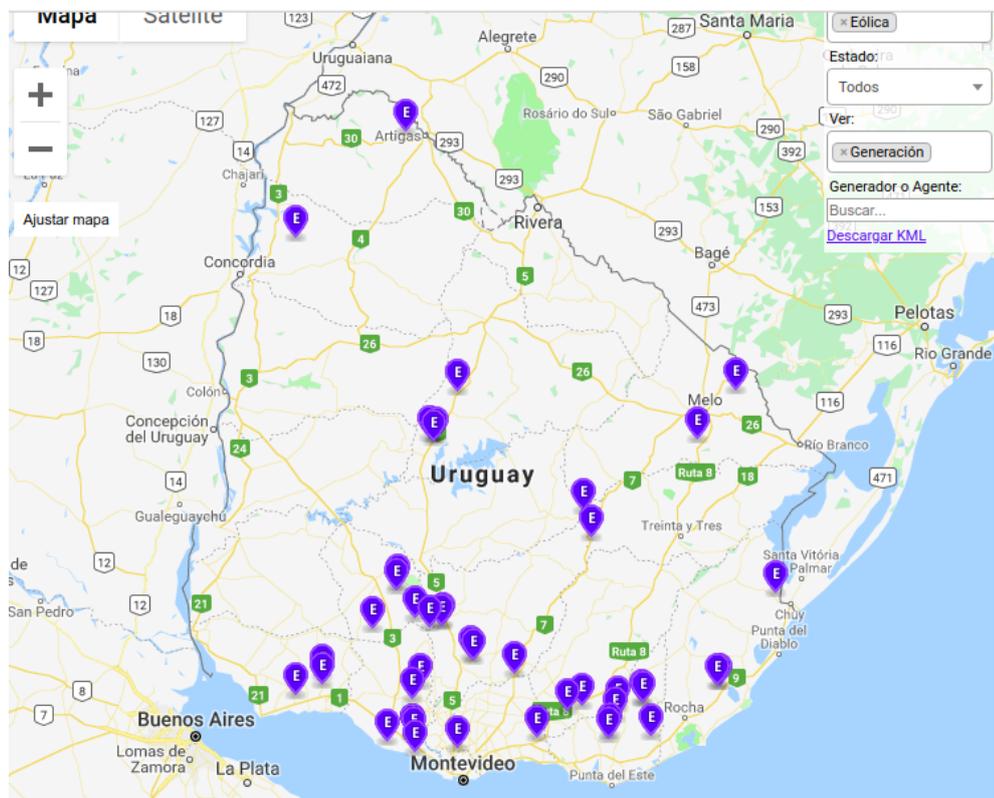


Figura 4.5: Ubicación de los parques eólicos. Fuente: UTE (2019).

La mayoría de los parques eólicos están ubicados en el sur del país, región que de acuerdo con el mapa eólico de Uruguay, MIEM (2009), tiene el mayor recurso eólico disponible. El primer parque eólico de gran escala conectado a la red, fue implementado en Uruguay en el año 2009. De dicha fecha hasta el presente momento, la eólica se caracterizó por su fuerte incremento, gracias a una política energética direccionada a la implementación de energías de fuentes renovables, buscando una mayor soberanía energética. La tabla 4.5 presenta la

potencia instalada en cada parque eólico.

Tabla 4.5: Potencia instalada y agente generador de los parques eólicos en Uruguay.
Fuente: UTE (2019).

Generador	Agente Generador	Pot. Instalada (MW)
Caracoles I	UTE	10
Caracoles II	UTE	10
Carapé I	Fingano I	51
Carapé II	Vengano S.A.	40
Colonia Arias	UTE+Accionistas	70
Corfrisa	Corporación Frigorífica del Uruguay	1.8
Cuchilla de Peralta I	Palmatir S.A.	50
Engraw	Engraw Export & Import Co. S.A.	3.6
Florida I	Polesine S.A.	50
Florida II	Glymont S.A.	49.5
Juan Pablo Terra	UTE	67.2
Julieta	Iweryl S.A.	3.6
Kiyú	Kiyú S.A.	49.2
La Bettina	Agroland S.A.	0.45
Libertad	Togely Compay S.A	7.7
Loma Alta Central I	Nuevo Manantial S.A.	14
Luz de Loma	Luz de Loma S.A.	20
Luz de Mar	Luz de Mar S.A.	18
Luz de Río	Luz de Río S.A.	50
Magdalena	Kentilux S.A.	17.2
Maldonado	R Del Sur S.A.	50
Maldonado II	R. del Este S.A.	50
María Luz	Togely Company S.A.	9.75
Marystay	Marystay S.A.	2
Melowind	Estrellada S.A.	50
Minas I	Generación Eólica Minas S.A.	42
Nuevo Manantial Central II	Nuevo Manantial S.A.	4
Nuevo Pastoral I	Vientos de Partorale S.A.	49.2
Palomas	Nicefield S.A.	70
Pampa	UTE+Accionistas	141.6
Parque Cerro Grande	Ladaner S.A.	50
Parque de Vacaciones UTE - ANTEL	UTE-ANTEL	0.15
Parque Eólico 18 de Julio	Ikerol Company S.A.	10
Parque Eólico Artilleros	UTE+Eletrobras S.A.	65.1
Peralta I GCEE	Agua Leguas S.A.	50
Peralta II GCEE	Agua Leguas S.A.	50
Rosario	Togely Company S.A.	9
Solis de Mataojo	Posadas e Vecino S.A.	10
Talas de Maciel I	Astidey S.A.	50
Talas de Maciel II	Cadonal S.A	50
Santa Fé	Lavadero de Lanás Blengio S.A.	1.8
Ventus I	Rep. Adm. de Fondos de Inv. S.A.	9
Villa Rodríguez	Togely Company S.A.	10
Valentines	UTE+Accionistas S.A.	70
TOTAL		1486.85

En base a los datos presentados, se percibe una fuerte presencia de las energías renovables en la matriz energética de Uruguay. Esa característica de la matriz Uruguaya se dio, en gran parte, por la implementación de las energías renovables no convencionales (eólica, fotovoltaica, biomasa), siendo esto posible gracias al respaldo de una política energética, planificada por el Ministerio de Industria, Energía y Minería (MIEM) y la Dirección Nacional de Energía

(DNE), con una mirada de largo plazo. Los lineamientos de dicha política energética comenzaron en el año 2005, siendo esta presentada y aprobada por el poder ejecutivo en el año 2008. Titulada como “Política Energética 2005-2030”, [MIEM-DNE \(2008\)](#), esta se basa en una mirada a largo plazo, pero con distintas metas a alcanzar a corto (5 años), mediano (10 a 15 años) y largo plazo (20 años y más). De acuerdo a [MIEM-DNE \(2008\)](#), el objetivo central de la política energética *“es la satisfacción de todas las necesidades energéticas nacionales, a costos que resulten adecuados para todos los sectores sociales y que aporten competitividad al país, promoviendo hábitos saludables de consumo energético, procurando la independencia energética del país en un marco de integración regional, mediante políticas sustentables tanto desde el punto de vista económico como medioambiental, utilizando la política energética como un instrumento para desarrollar capacidades productivas y promover la integración social”*. Dicha política energética implementada en Uruguay, tuvo como base 4 ejes estratégicos: eje institucional, eje de la oferta, eje de la demanda y eje social. La tabla 4.6 presenta por tipo de fuente, la potencia instalada (MW) y el porcentaje en relación al total de potencia instalada en la matriz energética de Uruguay.

Tabla 4.6: Participación de las distintas fuentes de energía en la matriz energética de Uruguay, tomando en base la potencia instalada (MW).

Tipo de Fuente	Potencia (MW)	Porcentaje en la Matriz Energética
Hidráulica	1538	35.62 %
Térmica/Fósil	651.77	15.09 %
Biomasa	413.3	9.57 %
Fotovoltaica	228.56	5.29 %
Eólica	1486.85	34.43 %
TOTAL	4318.48	100 %

El “Informe Anual 2017”, [ADME \(2018\)](#), presenta para este año, la participación por fuente en la generación total del Sistema Interconectado Nacional (SIN). En dicho informe, las hidráulicas del Río Negro (Constitución, Dr. Gabriel Terra y Rincón de Baygorria) y la del Río Uruguay (Salto Grande), son presentadas separadas cuanto a sus generaciones de energía. La suma de la generación de todas las hidráulicas de Uruguay para el año 2017, fue de 58.12 %, en comparación con la suma de generación de todas las distintas fuentes de la matriz energética en Uruguay. Otro dato presentado en [ADME \(2018\)](#), es la baja participación de la energía térmica/fósil en la generación de energía

eléctrica, con 1.83%. Esta baja participación de la energía térmica/fósil, es un buen indicador del logro de la política energética implementada en el país, visto que esta busca disminuir las emisiones de gases de efecto invernadero, y además disminuir los costos de generación de energía, siendo la generación térmica/fósil en Uruguay, la fuente más cara en términos de US\$/MWh. La figura 4.6, presenta la tabla comentada anteriormente.

Fuente	MWh	Participación de cada fuente en la generación total (%)
Hidráulica Río Negro	2.393.386,00	19,47
Hidráulica Salto Grande	4.751.386,00	38,65
Térmica	224.829,00	1,83
Eólica	3.766.822,00	30,64
Solar	253.161,00	2,06
Biomasa	902.436,00	7,34
Importación	2.917,00	0,02
TOTAL	12.294.937,00	100
Exportación	1.461.720,00	
Consumos de generación	49.209,00	
ABASTECIMIENTO DEMANDA NACIONAL	10.784.008,00	

Figura 4.6: Participación por fuente en la generación total del Sistema Interconectado Nacional (SIN) en el año de 2017. Fuente: ADME (2018).

La figura 4.7, presenta los intercambios de energía de importación/exportación (MWh) para el periodo 2011-2017.

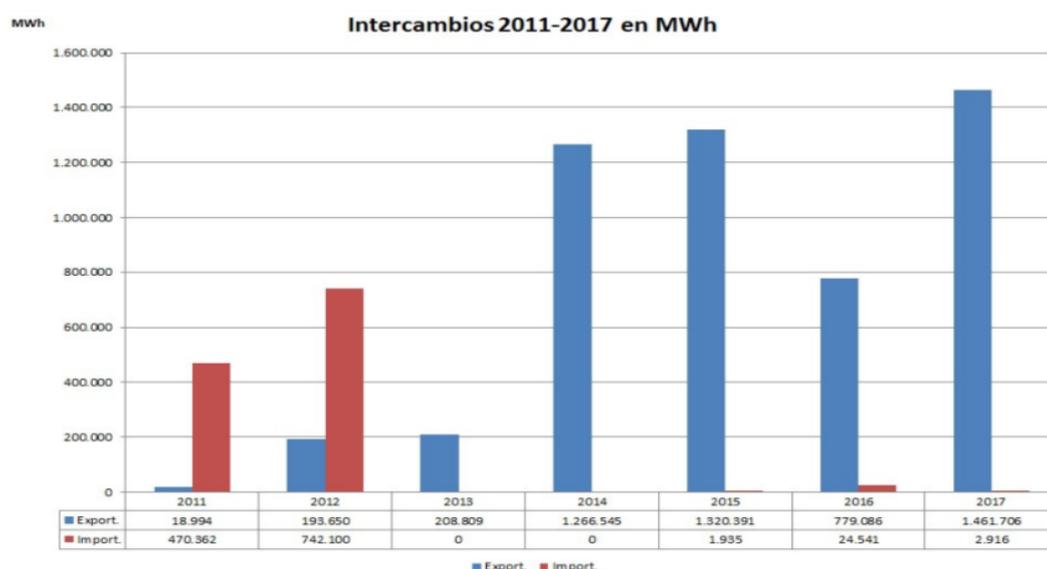


Figura 4.7: Intercambios de Energía, Importación/Exportación (MWh), ADME (2018).

En base a la figura 4.7, se verifica que a partir del año 2013, Uruguay se

tornó un país netamente exportador de energía eléctrica a sus vecinos Argentina y Brasil. Durante este período es que se tornó más significativa la implementación de las energías renovables no convencionales, donde se destaca la energía eólica. Con esta política energética implementada, Uruguay dejó de ser importador de energía de los países vecinos, a ser exportador, teniendo así una doble ventaja, que es el abastecimiento de la demanda interna, así como la venta de los excedentes.

Para proporcionar todo el abastecimiento de la demanda, así como permitir los intercambios de energía con Argentina y Brasil, Uruguay dispone de un sistema interconectado nacional (SIN), con las siguientes características presentadas en la figura 4.8.

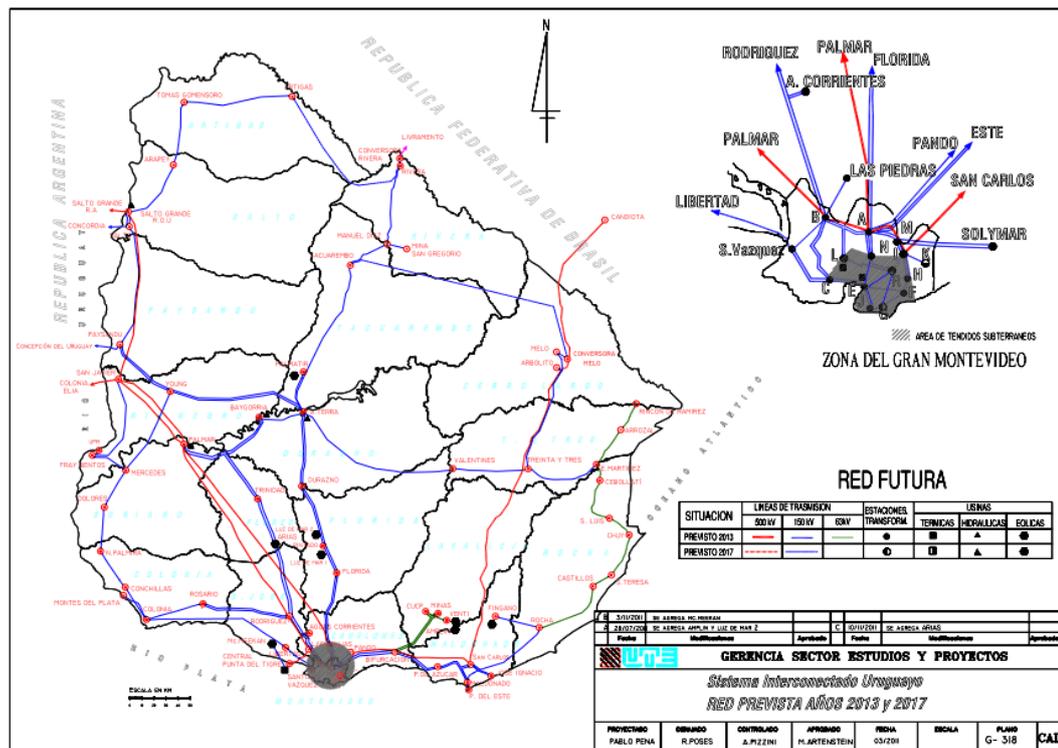


Figura 4.8: Sistema Interconectado Nacional (SIN) de Uruguay, UTE (2017).

El intercambio de energía con Argentina se da por dos líneas de transmisión de 500 kV ubicada en Salto Grande, con capacidad de interconexión de aproximadamente 2000 MW. Con Brasil el intercambio se da por Melo-Candiota via una línea de 500 kV y capacidad de interconexión de aproximadamente 500 MW y por Rivera- Santana do Livramento, por una línea de 150 kV y capacidad de interconexión de 70 MW.

Capítulo 5

Modelo Numérico de Mesoescala

Los modelos numéricos de mesoescala, buscan predecir numéricamente las condiciones futuras de la atmósfera, a partir de condiciones iniciales dadas por modelos de circulación global de la atmósfera en un área limitada, que a su vez reciben como entrada datos de una red de mediciones de variables meteorológicas, que está distribuido en distintos puntos de la superficie, mares, océanos y en la atmósfera terrestre. La figura 5.1 presenta de manera resumida el funcionamiento de un modelo de mesoescala.

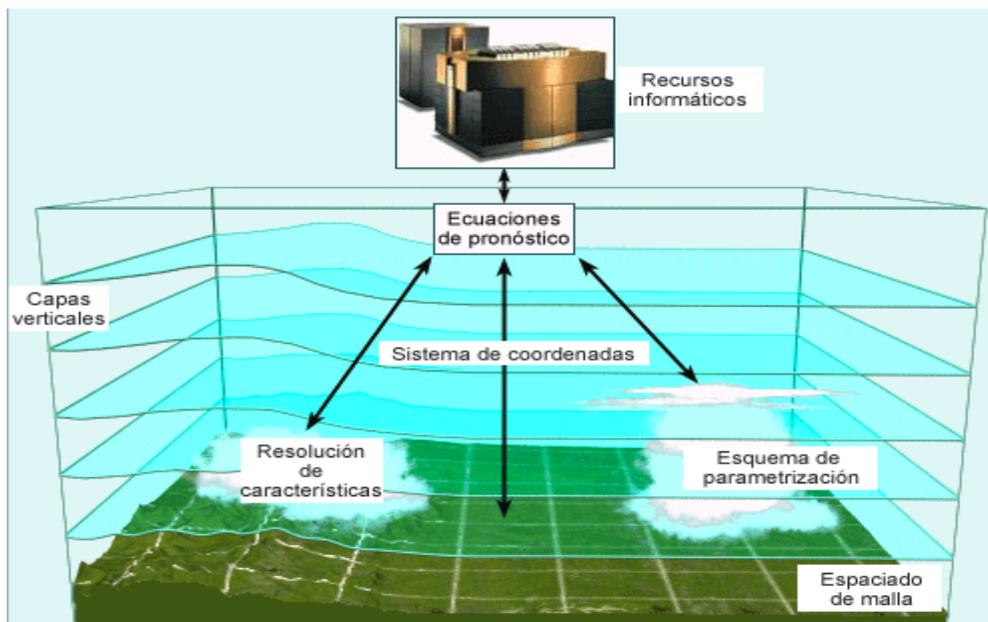


Figura 5.1: Resumen del funcionamiento de un modelo numérico de mesoescala. Fuente: [Meted \(2007\)](#).

Para resolver numéricamente las ecuaciones matemáticas que describen las leyes físicas del movimiento y conservación de la energía (ecuaciones básicas o primitivas) de la dinámica, desarrollo de los procesos físicos (parametrizaciones físicas) y condiciones atmosféricas, es necesario un considerable recurso informático, con un significativo poder de cómputo. Para esto son utilizados normalmente varios procesadores en paralelo o supercomputadoras (cluster).

Las ecuaciones que describen los procesos físicos son denominadas de parametrizaciones físicas, y buscan predecir los posibles estados de la atmósfera, en base a las condiciones iniciales.

Los modelos numéricos de mesoescala, así como los de circulación general de la atmósfera, discretizan el espacio y el tiempo en puntos por medio de grillas tridimensionales. Las grillas de los modelos numéricos varían la resolución en sentido horizontal y vertical. La figura 5.2 presenta gráficamente la discretización espacial de la superficie terrestre.

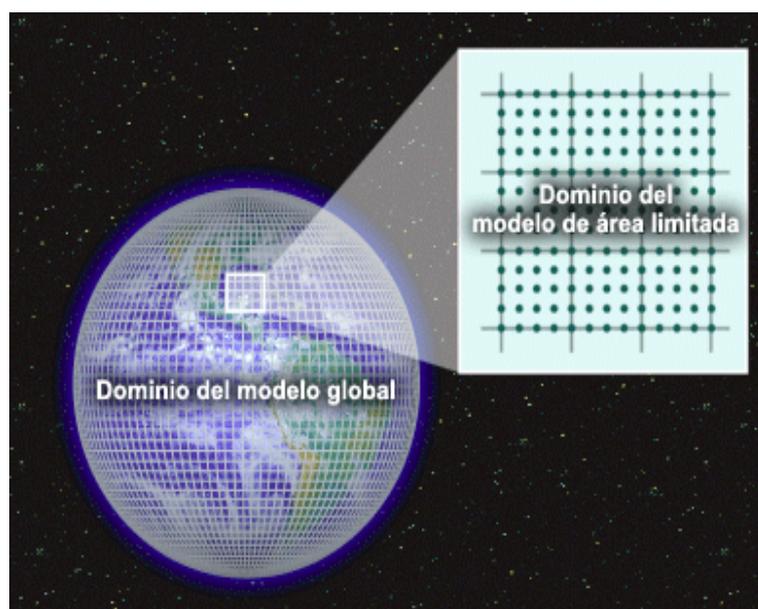


Figura 5.2: Discretización espacial del globo terrestre en niveles verticales y horizontales. Fuente: [Meted \(2010\)](#).

Al aumentar la resolución, los recursos informáticos necesarios también aumentan, porque el modelo debe calcular los valores para un mayor número de puntos de malla, [Meted \(2007\)](#). Próximo de la superficie terrestre se suele hacer una malla más fina, de modo a capturar la transferencia de calor y humedad en la capa límite planetaria producida por el calentamiento diurno de la superficie.

Los modelos de mesoescala están basados en ecuaciones básicas de la mecánica de los fluidos, siendo que dichos modelos deben cumplir en forma individual y simultánea en sus códigos los principios de conservación de la circulación de la atmósfera, los cuales son:

- Balance de masa
- Balance de calor
- Balance de la cantidad de movimiento
- Balance del agua
- Balance de otros gases y aerosoles

Con la ecuación de conservación de la cantidad de masa 5.1, se supone que la masa en la atmosfera terrestre no tiene ni sumideros ni fuentes, Pielke (2013).

$$-\left[\frac{\partial}{\partial x} \rho u + \frac{\partial}{\partial y} \rho v + \frac{\partial}{\partial z} \rho w \right] = \frac{\partial \rho}{\partial t} \quad (5.1)$$

En la ecuación 5.1, $\frac{\partial}{\partial x}$, $\frac{\partial}{\partial y}$, $\frac{\partial}{\partial z}$ representan las derivadas en el espacio x, y, z respectivamente, ρu , ρv y ρw representan el producto de la densidad y la velocidad en las componentes x, y, z del espacio, y $\frac{\partial \rho}{\partial t}$ representa la derivada local de la densidad en el tiempo.

La ecuación de balance de calor 5.2, (también llamada de ecuación de temperatura potencial o ecuación de la energía) utilizada en los modelos de mesoescala.

$$\frac{\partial \theta}{\partial t} = -u \frac{\partial \theta}{\partial x} - v \frac{\partial \theta}{\partial y} - w \frac{\partial \theta}{\partial z} + S_{\theta} = -\vec{V} \cdot \nabla \theta + S_{\theta} \quad (5.2)$$

En la ecuación 5.2, $\frac{\partial \theta}{\partial t}$ representa el cambio local en el tiempo de la temperatura potencial, $u \frac{\partial \theta}{\partial x}$, $v \frac{\partial \theta}{\partial y}$, $w \frac{\partial \theta}{\partial z}$ representan el producto de la velocidad (u, v, w) en tres dimensiones del espacio (x, y, z) por la temperatura potencial en dichas dimensiones del espacio, y S_{θ} representa las fuentes y sumideros de calor expresadas por los cambios en la temperatura potencial.

El balance de la cantidad de movimiento se expresa en la segunda ley de

Newton, que establece que una fuerza ejercida sobre un objeto provoca una aceleración ($\vec{F} = m \cdot \vec{a}$). La forma estándar de presentación de la conservación de cantidad de movimiento es presentada en la ecuación 5.3.

$$\frac{\partial \vec{V}}{\partial t} = -\vec{V} \nabla \vec{V} - \frac{1}{\rho} \nabla p - g\vec{k} - 2\Omega \times \vec{V} \quad (5.3)$$

En la ecuación 5.3, $\frac{\partial \vec{V}}{\partial t}$ representa la derivada local de la velocidad en el tiempo, \vec{V} representa la velocidad en función del tiempo y espacio tridimensional, $\nabla \vec{V}$ representa el gradiente de velocidad, $\frac{1}{\rho} \nabla p$ representa la fuerza del gradiente de presión, $g\vec{k}$ representa la fuerza de gravedad el el vector de dirección k en el espacio tridimensional (vertical en relación a la superficie), y $2\Omega \times \vec{V}$ representa la fuerza de Coriolis, la cual se da por la rotación de la Tierra en su propio eje.

El balance del agua, parte del principio que la misma puede estar en tres formas: sólido, líquido y vapor. Para escribir la conservación de esta substancia, se debe seguir los cambios de fase y su movimiento a través de la atmósfera, Pielke (2013). La ecuación 5.4 presenta la formulación matemática de dicha conservación.

$$\frac{dq_n}{dt} = S_{qn}, n = 1, 2, 3... \quad (5.4)$$

En la ecuación 5.4, el termino “n” puede ser expreso por los números 1,2 y 3, donde cada valor representa una proporción de la masa del agua para los distintos estados físicos, para un mismo volumen. Así, el término S_{qn} se refiere a los procesos por los cuales el agua sufre un cambio de fase, así como el agua perdida o generada por reacciones químicas, Pielke (2013).

La conservación de la cantidad de otros gases y aerosoles es presentada matemáticamente por la ecuación 5.5.

$$\frac{dX_m}{dt} = S_{xm}, n = 1, 2, 3..., M, \quad (5.5)$$

En la ecuación 5.5 X_m se refiere a todas las especies químicas (excepto el agua) y se expresa por la masa de dicha substancia en una masa de aire. El término S_{xm} , incluye los cambios de estado (análogos a los que se realizan para el agua), así como las transformaciones químicas, precipitación y sedimentación, Pielke (2013).

Los modelos de pronóstico están divididos en modelos hidrostáticos y no

hidrostáticos. Los modelos hidrostáticos suponen que hay un equilibrio entre el peso de la atmósfera, que ejerce una fuerza de presión hacia abajo, y la fuerza del gradiente de presión vertical. A su vez, los modelos de pronósticos no hidrostáticos, como el WRF, por ejemplo, incluyen ecuaciones para los movimientos verticales que no se emplean en los modelos hidrostáticos.

Los modelos numéricos de mesoescala, pronostican las variables meteorológicas, a partir del uso de las parametrizaciones físicas. Dichas parametrizaciones son esquemas numéricos que representan los procesos físicos que ocurren en la atmósfera. Las principales parametrizaciones físicas de los modelos numéricos de mesoescala son la de radiación, nubes, microfísica y de capa límite atmosférica e intercambio de calor con la superficie. La figura 5.3 presenta un esquema de los procesos físicos que ocurren de modo simultáneo en la atmósfera terrestre.



Figura 5.3: Principales procesos físicos que ocurren en la atmósfera terrestre. Fuente: Meted (2010).

Entre los modelos numéricos de mesoescala se destaca el WRF. Dicho mo-

delo tiene una grilla de escalonamiento conocida como grilla C de Arakawa. El modelo utiliza métodos de integración temporal de tercer orden de Runge-Kutta. El código del modelo WRF tiene programas de inicialización en casos idealizados (`ideal.exe`) y casos reales (`real.exe`), un módulo de integración numérica (`wrf.exe`).

Los módulos de ejecución del modelo son el WRF Preprocessing System (WPS) y el modelo WRF, lo cual puede ser WRF-ARW o WRF-NMM (dependiendo de la versión utilizada). El módulo WPS contiene tres submódulos que son el `geogrid`, `ungrib` y `metgrid`. El `geogrid` crea los datos terrestres a partir de los datos geográficos estáticos obtenidos de una fuente de datos externa. El `ungrib` descompacta los archivos meteorológicos en formato GRIB (obtenidos por fuente externa) y los compacta para un formato intermediario. El `metgrid`, interpola los datos meteorológicos horizontalmente para el dominio elegido para el estudio, siendo la salida del `metgrid.exe` usada como dato de entrada para el WRF, mediante el `real.exe`. Por fin, el módulo `real.exe` hace la interpolación vertical sobre el área de interés, además de elegir el conjunto de parametrizaciones físicas. El `wrf.exe` ejecuta el modelo numérico con todas las configuraciones elegidas en los módulos anteriores, [WRF-ARW \(2019\)](#). La figura 5.4, presenta el diagrama de bloques para una ejecución típica de casos reales del modelo WRF.

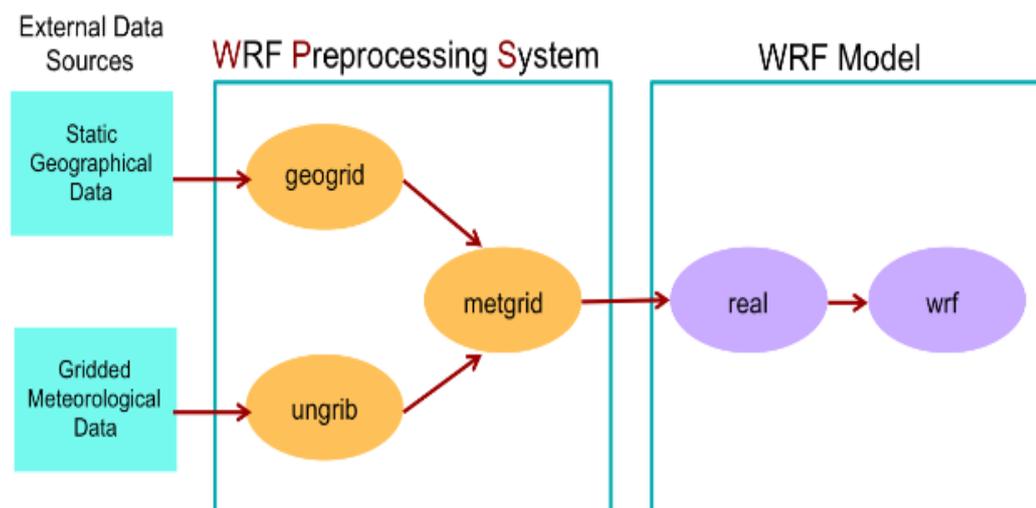


Figura 5.4: Diagrama de bloques para una ejecución típica del modelo WRF. Fuente: [WRF-ARW \(2019\)](#).

5.1. Parametrizaciones Físicas

Las parametrizaciones físicas son esquemas numéricos que buscan resolver procesos físicos presentes en la atmósfera terrestre, como la radiación de onda corta (solar) y de onda larga (terrestre), la transferencia mecánica de calor y humedad entre en el suelo y la capa límite atmosférica (CLA), [Meted \(2010\)](#).

Esta sección, presenta de manera resumida la caracterización de las principales parametrizaciones físicas del modelo WRF.

5.1.1. Radiación y Microfísica

Las parametrizaciones de microfísica, radiación de onda corta y radiación de onda larga describen procesos que son responsables por la formación de las nubes, difusión, refracción y reflexión de la radiación incidente en la atmósfera terrestre.

Los procesos de radiación de onda corta (solar) y de onda larga (terrestre) ocurren a escalas temporales y espaciales muy pequeñas y se ven fuertemente afectados por la composición local de la atmósfera. A medida que la radiación solar directa atraviesa la atmósfera, su intensidad disminuye debido a la absorción y esparcimiento de las nubes, aerosoles, así como diversos gases, y también por la reflexión y absorción provocada por estas nubes, aerosoles y gases. Parte de esta radiación solar reflejada y dispersada también alcanza la superficie en forma de radiación solar difusa, [Meted \(2014\)](#).

El planeta emite energía hacia el espacio, pero en longitudes de onda más largas. Conforme esta energía se desplaza hacia regiones más altas de la atmósfera, es absorbida por los gases de efecto invernadero, las nubes y los aerosoles. A su vez, dichos absorbentes atmosféricos reemiten esta energía de onda larga, pero en cualquier dirección y a una intensidad que viene determinada por la temperatura del objeto irradiante.

La parametrización de los procesos de radiación atmosféricos en los modelos numéricos de mesoescala implica: dividir la atmósfera en capas y pronosticar, diagnosticar o prescribir la cantidad de nubes, gas absorbente y/o aerosoles en cada capa; determinar la cantidad de radiación entrante absorbida por cada capa y la cantidad total de radiación de onda corta que llega a la superficie; calcular la cantidad de radiación de onda larga absorbida y reemitida en cada capa del modelo. A su vez la microfísica, es responsable por los procesos que

controlan la formación de nubes, gotas y cristales de hielo, su crecimiento y caída como precipitación.

Para el desarrollo de este trabajo, se utilizaron como parametrizaciones de radiación de onda corta, radiación de onda larga y microfísica, del modelo WRF-ARW, los siguientes esquemas:

- Radiación de onda corta: Dudhia, [Dudhia \(1989\)](#).
- Radiación de onda larga: RRTM, [Mlawer \(1997\)](#).
- Microfísica: Purdue Lin, [Chen \(2002\)](#).

5.1.2. Cumulus y Tormentas Convectivas

La parametrización de cumulus, que es un tipo de nube, actúa en un modelo numérico de modo a resolver numéricamente el proceso de convección, lo cual es el responsable por redistribuir el calor y mezcla vertical, responsables por producir la precipitación, [Stensurd \(2012\)](#).

Para el desarrollo de este trabajo se utilizó la parametrización de formación de nubes del tipo cumulus, el esquema Kain-Fritsch, [Chen \(2004\)](#).

5.1.3. Intercambio de calor con la superficie

La superficie terrestre interactúa con la radiación solar entrante que queda después de la dispersión, reflexión y absorción por parte de la atmósfera. El grado de absorción de la radiación solar y el subsiguiente intercambio de calor sensible y humedad entre la superficie y la atmósfera (y entre la superficie y el subsuelo) depende del tipo de superficie (tierra, agua, hielo, nieve), de la vegetación, del tipo de suelo y de la rugosidad del terreno, [Meted \(2010\)](#).

Para el desarrollo de este trabajo, la interacción entre el suelo y la superficie atmosférica es presentada por el modelo unified Noah land-surface model, [Noah \(2014\)](#).

5.1.4. Capa Límite Atmosférica y Capa de Superficie

Las parametrizaciones físicas capa límite atmosférica buscan describir los procesos superficiales y de capa límite atmosférica, que permiten pronosticar

la velocidad de fricción y otras variables micrometeorológicas. En los esquemas numéricos de la CLA dentro de los modelos de mesoescala como el WRF se desarrollan diferentes estrategias para la descripción de los procesos de difusión turbulenta de calor, cantidad movimiento y masa (agua y otras especies como ser contaminantes), [Porrini \(2018\)](#).

En este trabajo se utilizaron las siguientes combinaciones entre las parametrizaciones de capa límite atmosférica (CLA) y capa de superficie (CS).

- Mellor-Yamada-Janjic (CLA) y Eta Similarity Scheme (CS): La parametrización de capa límite atmosférica Mellor-Yamada-Janjic pronostica la energía cinética turbulenta, a partir de los flujos de calor de la superficie y fricción en la misma, así como la mezcla y la difusión vertical en la capa límite atmosférica, [Janjic \(2014\)](#). La parametrización de Mellor-Yamada-Janjic es un esquema unidimensional de energía cinética turbulenta que pronostica la mezcla vertical de modo local, [NCAR \(2019\)](#).

- Yonsei University (CLA) y Revised MM5 (CS): La parametrización de Yonsei University es un esquema de primer orden que utiliza algunos coeficientes de difusión turbulenta no locales para calcular los flujos turbulentos, [Hong \(2006\)](#). Pronostica la difusión vertical con un coeficiente no local de mezcla por turbulencia en la capa límite planetaria.

Dichas parametrizaciones han sido probadas y se ha evaluado como de buen desempeño en la región geográfica de estudio [Lucas \(2016\)](#), [Gutiérrez \(2018c\)](#).

5.2. Modelos de Pronóstico Operativo

De acuerdo a [Gutiérrez \(2011\)](#), desarrollar una herramienta de predicción, implica generar información de lo que sucederá en el futuro en términos de la descripción de la evolución temporal de una variable “p”, a partir de la información disponible en el presente y pasado.

Gracias a la evolución de los modelos de circulación general de la atmósfera, debido a factores como el aumento de la capacidad de procesamiento, mejora en la representación de procesos de pequeña escala en la atmósfera y mejora en la observación y asimilación de datos, los modelos de pronósticos operativos pasaron por una mejora de desempeño a lo largo del tiempo, [Kalnay \(2003\)](#). Esta mejora de desempeño descrita por [Kalnay \(2003\)](#), hizo que los modelos regionales también tuviesen sus beneficios directos, visto que dichos modelos utilizan como condiciones iniciales y de frontera las salidas de los modelos de

circulación general de la atmósfera. El aumento del poder de cómputo, propició también una mayor capacidad de almacenamiento de datos, siendo que esto permitió tener disponible una mayor base de datos atmosféricos, permitiendo así realizar un análisis más profundo sobre el comportamiento de la atmósfera en distintas condiciones.

Capítulo 6

Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA's) a lo largo de las últimas décadas han despertado gran interés en distintas áreas de estudio, debido a su particular estructura inspirada en las redes neuronales biológicas (RNB's). Las RNA's están compuestas por elementos de cómputo simples (neuronas), las cuales están interconectadas en paralelo, y con el conocimiento adquirido a partir de algoritmos de aprendizaje, se distinguen de la mayoría de los modelos estadísticos tradicionales basados en reglas y probabilidades, [Gutiérrez \(2004\)](#).

Según [Haykin \(2009\)](#) una RNA es un procesador que permite hacer cálculos en forma paralela de modo masivo y en forma distribuida, estando constituido el proceso de cálculo por unidades de procesamiento simple (neurona artificial), que tienen propensión natural de almacenar conocimiento experimental y tornarlo disponible para el uso. [Braga \(2000\)](#) define las RNA's como sistemas paralelos distribuidos compuestos por unidades de procesamiento simple (nodos, neuronas artificiales) dispuestas en una (capa única) o más capas (multicapa), que calculan funciones matemáticas (normalmente no lineales), siendo esta estructura basada en el cerebro humano. En términos generales se puede decir que las RNA's son aproximadores universales de funciones, permitiendo identificar la mejor forma de mapear un conjunto de valores de entrada en valores de salida.

Las redes neuronales artificiales son clasificadas de acuerdo a sus características más notables. En base a esto la clasificación de las RNA's puede ser en base a su estructura y al tipo de aprendizaje. Considerando la estructura, las RNA's pueden ser clasificadas en cuanto al número de capas (capa única

o multicapa) y en cuanto al tipo de conexiones (prealimentada o recurrentes). Las RNA's del tipo capa única tienen solamente una capa de neuronas, que son una capa de salida. Las RNA's multicapa tienen una o más capas ocultas de neuronas y una capa de salida. A su vez, las RNA's de conexiones del tipo prealimentada (feed-forward en inglés), no forman un ciclo entre sus conexiones. Las RNA's de conexiones del tipo recurrente tiene como característica principal formar un ciclo de retroalimentación entre sus conexiones.

En cuanto al tipo de aprendizaje, básicamente las RNA's pueden clasificarse en dos tipos, que son el aprendizaje no supervisado y aprendizaje supervisado. En el aprendizaje supervisado, durante el entrenamiento son presentados los datos de entrada y datos objetivo a la red. Para el aprendizaje no supervisado, no son presentados los datos objetivo durante el entrenamiento. [Haykin \(2009\)](#) resalta que el proceso de aprendizaje es realizado por los algoritmos de aprendizaje, cuya función es modificar los pesos sinápticos (conexiones entre los datos de entrada y las neuronas artificiales, así como entre neuronas artificiales de distintas capas) la red de una forma ordenada para alcanzar un objetivo de proyecto deseado.

Además el autor destaca que una RNA es similar al cerebro humano en dos aspectos:

- conocimiento adquirido a través de un proceso de aprendizaje.
- fuerzas de conexión entre las neuronas, conocidas como pesos sinápticos, utilizada para almacenar el conocimiento adquirido.

Una de las principales capacidades que hace atractivo el uso de las RNA's, es la generalización frente a nuevos datos de entrada en la red, además de su capacidad de resolver problemas de naturaleza no lineal. La generalización se da en base al conocimiento adquirido en el proceso de entrenamiento, lo que muestra que además de mapear los datos de entrada y salida, las redes neuronales son capaces de extraer informaciones implícitas en los datos de ejemplo (entrenamiento).

A continuación se presenta un breve resumen histórico del desarrollo de las RNA's, la inspiración biológica y la caracterización de las neuronas artificiales como unidad de cálculo. Luego son profundizadas las principales arquitecturas de RNA's, así como algoritmos de entrenamiento. Al final se describen los parámetros que caracterizan los modelos matemáticos de una red neuronal artificial.

6.1. Histórico de las RNA's

Las redes neuronales artificiales tuvieron sus primeros desarrollos a partir de los años 1940, con el modelo de una neurona artificial como unidad de cálculo. Después el desarrollo de la tecnología de las RNA's tuvo momentos de auge y descrédito a lo largo de las décadas siguientes, hasta llegar al año 1986 con el redescubrimiento de un método de entrenamiento denominado retropropagación. A partir del redescubrimiento de la retropropagación el desarrollo de las redes neuronales sigue hasta los días actuales en ritmo fuerte, con cada vez más utilización en distintas áreas de conocimiento.

Según [Yadav \(2004\)](#), la historia de las redes neuronales artificiales puede ser dividida en cuatro períodos: el comienzo de las redes neuronales, primer período de años dorados, años de descrédito y resurgimiento de los años dorados, a partir de la experimentación biológica, modelación y simulación computacional e implementación en hardware.

La figura 7.8 presenta una línea de tiempo de los desarrollos más relevantes que marcaron los distintos períodos en el estudio de las redes neuronales artificiales.

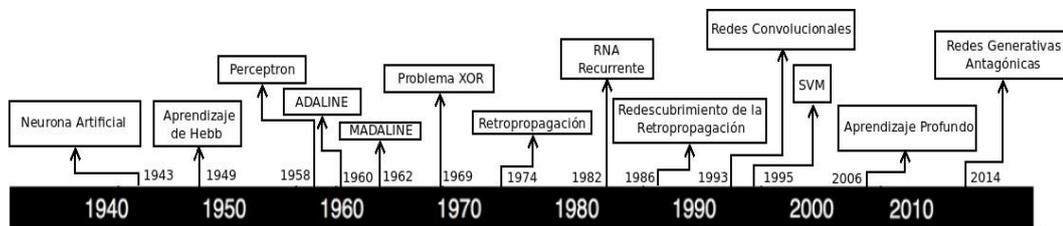


Figura 6.1: Principales desarrollos de las redes neuronales artificiales a lo largo del tiempo. Fuente: Adaptado de [Bream \(2017\)](#).

En el comienzo de las redes neuronales se destaca el estudio de [McCulloch and Pitts \(1943\)](#), que presenta por primera vez una neurona artificial como unidad de cálculo basada en el comportamiento de las neuronas biológicas. Dicha neurona artificial buscaba representar matemáticamente la activación de una neurona humana en un sistema nervioso. La activación de las neuronas estaban basadas en el denominado sistema de activación “todo o nada”, lo cual la salida era 0 (no activada) o 1 (activada). Luego [Hebb \(1949\)](#) aborda por primera vez el tema del aprendizaje de las RNA's, donde explicita que el aprendizaje se da a partir de la plasticidad de las conexiones entre las neuronas, o sea, de la modificación de los pesos sinápticos entre las neuronas. La teoría

de aprendizaje se Hebb se basa en el refuerzo de las conexiones sinápticas entre los nodos activados. Tanto el estudio de [McCulloch and Pitts \(1943\)](#), como el de [Hebb \(1949\)](#), fueron desarrollados buscando entender las redes neuronales del cerebro humano.

El período de los años dorados comienza con el desarrollo del perceptron por [Rosenblatt \(1958\)](#), lo cual describe que a partir de impulsos del ambiente externo el perceptron ajustaba los valores de los pesos sinápticos, siendo un modelo útil para clasificador patrones linealmente separables. Dicho modelo fue descrito en base a las señales recibidas por la retina humana, la cual se propaga por impulsos hasta las neuronas de la capa de salida, siendo las conexiones con estas neuronas de salida ajustables. La figura 6.2 presenta el modelo del perceptron desarrollado por [Rosenblatt \(1958\)](#).

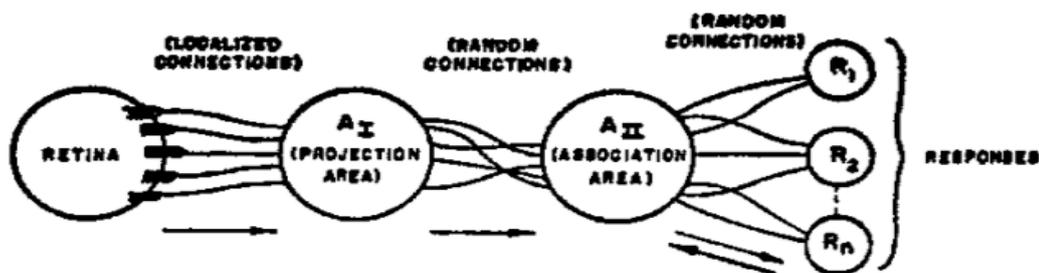


Figura 6.2: Modelo de perceptron en base a señales enviada por la retina a una capa de neuronas de salida. Fuente: [Rosenblatt \(1958\)](#).

Luego [Widrow and Hoff \(1960\)](#) desarrolla una nueva técnica de aprendizaje, la cual está basada en la neurona artificial de [McCulloch and Pitts \(1943\)](#). Dicha técnica de aprendizaje conocida como regla delta, utiliza un método de gradiente local para cambiar los pesos sinápticos, de modo a minimizar el error en la salida de una neurona, siendo el error medido, la diferencia del valor estimado por la neurona y el valor de salida deseado. El modelo MADALINE (Múltiple ADaptative LINear Element) es presentado por [Widrow and Goldstein \(1962\)](#), lo cual presenta la misma idea de cálculo del modelo ADALINE (ADaptative LINear Element), [Widrow and Hoff \(1960\)](#), pero con una capa oculta y una la capa de salida.

La figura 6.3 presenta el modelo de “ADaptative LINear Element” (ADALINE, a la izquierda) y el “Múltiple ADaptative LINear Element” (MADALINE, a la derecha), donde es posible verificar la estructura de capa única y multicapa respectivamente de cada modelo.

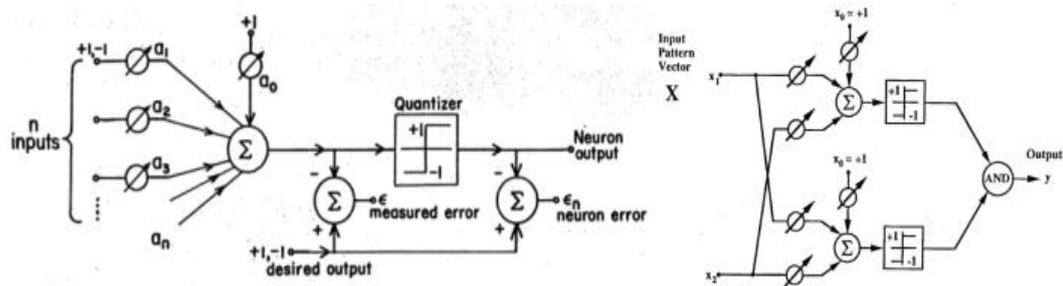


Figura 6.3: Esquema del modelo ADALINE (izquierda) y MADALINE (derecha). Fuentes: [Widrow and Hoff \(1960\)](#) y [Widrow and Goldstein \(1962\)](#).

El período de oscuridad o descrédito de las redes neuronales artificiales se dio a partir del trabajo de [Minsky and Papert \(1969\)](#), lo cual mostró las limitaciones del perceptrón. Se hizo énfasis en que el perceptrón de capa única solamente era capaz de resolver problemas linealmente separables, cuya solución puede ser resuelta por modelos estadísticos simples. Además el perceptrón multicapa no tenía capacidades superiores al perceptrón de capa única, debido al problema de atribución de crédito en la capa oculta. En problemas de naturaleza no lineal el perceptrón no era capaz de resolverlos ni con capa única ni con estructura multicapa. A partir del trabajo de Minsky hasta el año 1985 las redes neuronales artificiales no tuvieron interés de estudio por parte de los investigadores a nivel mundial. Durante este período, [Werbos \(1974\)](#) presenta por primera vez el algoritmo de entrenamiento de retropropagación del error para una red neuronal multicapa. [Hopfield \(1982\)](#) presenta un red neuronal del tipo recurrente, la cual se caracteriza por una realimentación, y la inclusión de delays en la salida de las capa(s) oculta(s), lo que da énfasis a las propiedades asociativas de una RNA. Debido al trabajo de [Minsky and Papert \(1969\)](#), los trabajos de [Werbos \(1974\)](#) y [Hopfield \(1982\)](#) no tuvieron una atención especial en este período.

A partir del trabajo de [Rumelhart \(1986b\)](#) se inicia el segundo período de “años dorados“ que se extiende hasta los días actuales. Se redescubre la retropropagación, y se muestra que la visión de [Minsky and Papert \(1969\)](#) era bastante pesimista en cuanto a las capacidades de una red de perceptrones multicapa. [Rumelhart \(1986b\)](#) demuestra que las RNA’s multicapa son capaces de resolver problemas complejos de difícil aprendizaje. Se suma a esto el avance de la microelectrónica y de la modelación computacional, para la retomada del interés en el tema.

Luego surgieron otros trabajos importantes en las RNA's como el de [Wu \(1993\)](#), con el desarrollo de las redes convolucionales, las cuales son muy utilizadas actualmente para la clasificación de imágenes. [Cortes and Vapnik \(1995\)](#) presenta las máquinas de vectores de soporte (SVM's, del inglés Support Vector Machines), método este relacionado con problemas de clasificación de clases y regresión. Durante este período, [Hinton and Salakhutdinov \(2006\)](#) presentan el aprendizaje profundo (deep learning, del inglés), lo cual es una subcategoría del aprendizaje automático largamente utilizado en los días actuales, que a partir de transformaciones no lineales múltiples busca modelar abstracciones de alto nivel. El aprendizaje profundo ha sido utilizado para tareas como reconocimiento de voz, procesamiento del lenguaje natural y visión por ordenador, entre otras. [Goodfellow \(2014\)](#) presenta las redes generativas antagónicas (GAN's, del inglés Generative Antagonic Networks), las cuales en base a un aprendizaje profundo, se usan para crear sonidos e imágenes hiperrealistas a partir de una base de imágenes y/o sonidos de ejemplos distintos a los que se quiera crear.

Este período de "segundo auge" de las RNA's sigue cada vez más fuerte, siendo utilizado en distintas áreas de conocimiento, resolviendo problemas muy complejos en todos los niveles, impulsando así el desarrollo de distintos productos y servicios a la población.

6.2. Inspiración Biológica

El sistema nervioso humano tiene como elemento central el cerebro, el cual es representado por la red neuronal que recibe continuamente informaciones y toma las decisiones "adecuadas", [Haykin \(2009\)](#). El sistema como un todo funciona a partir de estímulos del ambiente externo, que son captados por receptores y transformados en impulsos eléctricos que llegan hasta el cerebro. Luego, los actuadores convierten estos impulsos en respuestas como salidas del sistema, como por ejemplo, los movimientos del cuerpo.

Las RNA's fueron desarrolladas inspiradas en la estructura de las redes neuronales biológicas (RNB's). El cerebro humano, es el principal elemento del sistema nervioso humano, está compuesto por una vasta red de neuronas interconectadas masivamente entre ellas de forma paralela. Esta red suele ser denominada red neuronal biológica.

Para el propósito de estudio del desarrollo de las RNA's y su inspiración,

se elige como elemento central de estudio en las RNB's, las neuronas. Las neuronas son las unidades básicas de señales del sistema nervioso, y cada neurona es una célula discreta cuyos diversos procesos surgen de su cuerpo celular [Neha Yadav \(2015\)](#). Las neuronas biológicas están densamente conectadas en paralelo, y se activan por conmutación eléctrica, acondicionadaa en gran medida por los procesos químicos, [Zurada \(1992\)](#).

Las neuronas biológicas son divididas en cuatro componentes principales: las dendritas, el cuerpo celular, el axón y las sinapsis. Las dendritas son las estructuras responsables por ser los receptores de señales del ambiente externo de la red, y tienen una forma de árbol. Las dendritas convierten las señales de ambiente en señales eléctricas y las transmite hasta el cuerpo celular. El cuerpo celular suma y calcula umbrales en base a las señales recibidas. El axón a su vez, es una simple fibra larga que lleva la señal hasta otra neurona. El punto de contacto entre una célula y la dendrita de otra célula es denominada sinapsis [Neha Yadav \(2015\)](#). La figura 6.4 muestra de modo simplificado las estructuras principales de una neurona biológica.

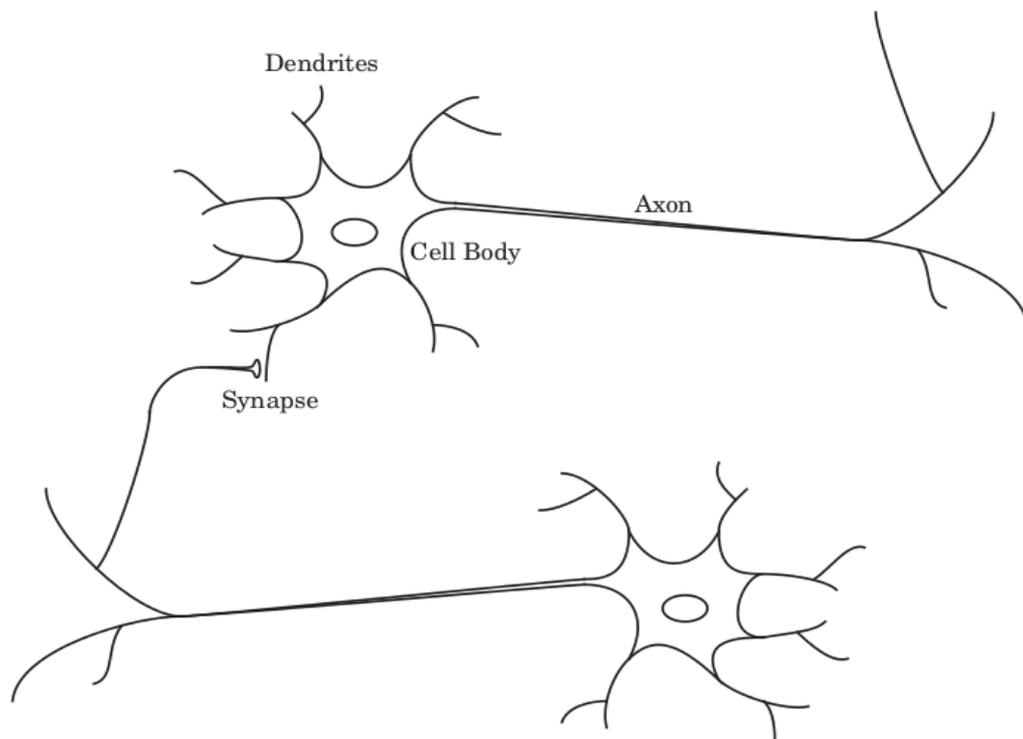


Figura 6.4: Diseño simplificado de dos neuronas biológicas. Fuente: [Neha Yadav \(2015\)](#).

La capacidad del cerebro humano de desarrollar funciones complejas surge

de la operación en paralelo de todos los 10^{11} nodos en el cerebro humano, Braga (2000).

6.3. Neurona Artificial

Una neurona artificial es la unidad de procesamiento fundamental para la operación de una RNA. Así como las neuronas biológicas, una neurona artificial recibe las señales externas, siendo estas, vectores que contienen valores de variables de entrada en este caso, y las convierten en salidas entre 0 y 1, que pueden ser activadas o no, dependiendo de la configuración y variables involucradas en la red.

Típicamente la salida de una neurona es normalizada, y tiene un intervalo de amplitud $[0,1]$ o $[-1,1]$, dependiendo del método de normalización. Las principales estructuras de una neurona artificial son la sinapsis, unión aditiva (suma) y función de activación Haykin (2009). La figura 6.5 presenta un modelo de neurona “k”, no lineal.

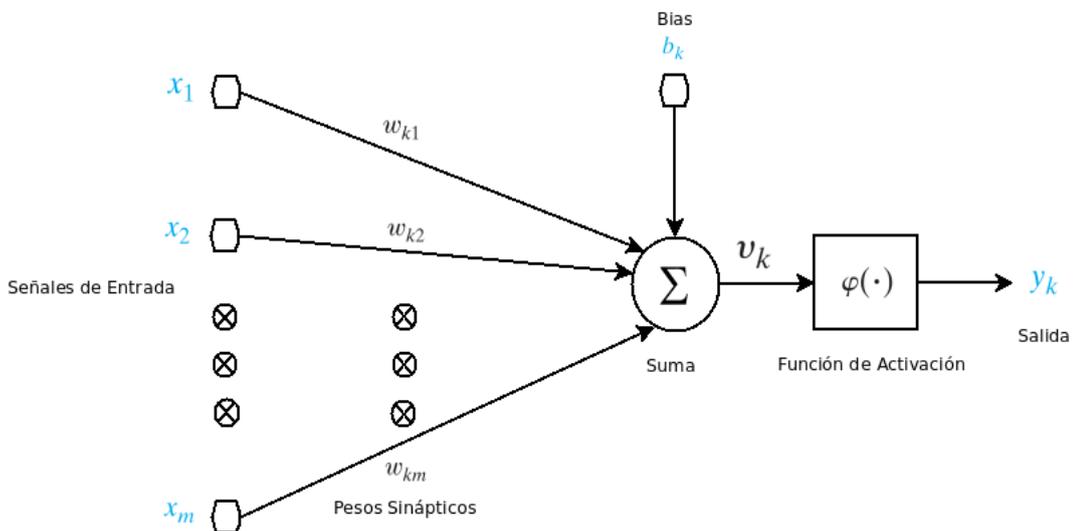


Figura 6.5: Modelo de neurona “k”, no lineal. Fuente: Adaptado de Haykin (2009).

En base a la figura 6.5, para la neurona “k”, se considera los siguientes aspectos para comprender el funcionamiento de una neurona artificial.

- *Señales de entrada:* son caracterizadas por vectores con valores que representan cada variable de entrada de una RNA (representados por x_1, x_2, \dots ,

x_m en la figura 6.5). Estos vectores son normalizados antes de ser procesados.

- *Sinapsis*: son las conexiones entre cada variable de entrada y la neurona. Cada sinapsis está caracterizada por un “peso” (w), que es particular a cada una. La señal de entrada “ X_j ” de la sinapse “ j ” conectada a la neurona “ k ” es multiplicada por el peso sináptico “ W_{kj} ”. Los valores de peso sináptico están comprendidos entre 0 y 1.

- *Peso Sináptico*: es el producto del valor del vector de entrada de una variable “ X ” conectada a la neurona “ k ” por una sinapse “ j ” por el peso de dicha sinapse. El peso sináptico es representado por la ecuación 6.1.

$$P_{kj} = W_{kj} * X_j \quad (6.1)$$

- *Suma*: es la parte de la neurona artificial donde son sumadas las señales de entrada con sus respectivos valores sinápticos, y suele ser representada como “ u_k ”, siendo una combinación lineal de la salida a partir de las entradas. La ecuación 6.2 representa de forma general el cálculo realizado por la suma de una neurona, siendo “ m ” el número de variables de entrada.

$$u_k = \sum_{j=0}^{j=m} X_j * W_{kj} \quad (6.2)$$

- *Propagación*: suma el bias asociado a la neurona “ k ” (b_k), al valor de la combinación lineal de la neurona “ k ” (u_k). Es representada por “ v_k ” y calculado por la ecuación 6.3.

$$v_k = \sum_{j=0}^{j=m} u_k + b_k \quad (6.3)$$

El bias para el cálculo de una neurona artificial suele ser utilizado como una entrada más, agregándose a él una sinapsis. La figura 6.6 muestra el bias de la neurona b_k y su configuración para el cálculo en la neurona.

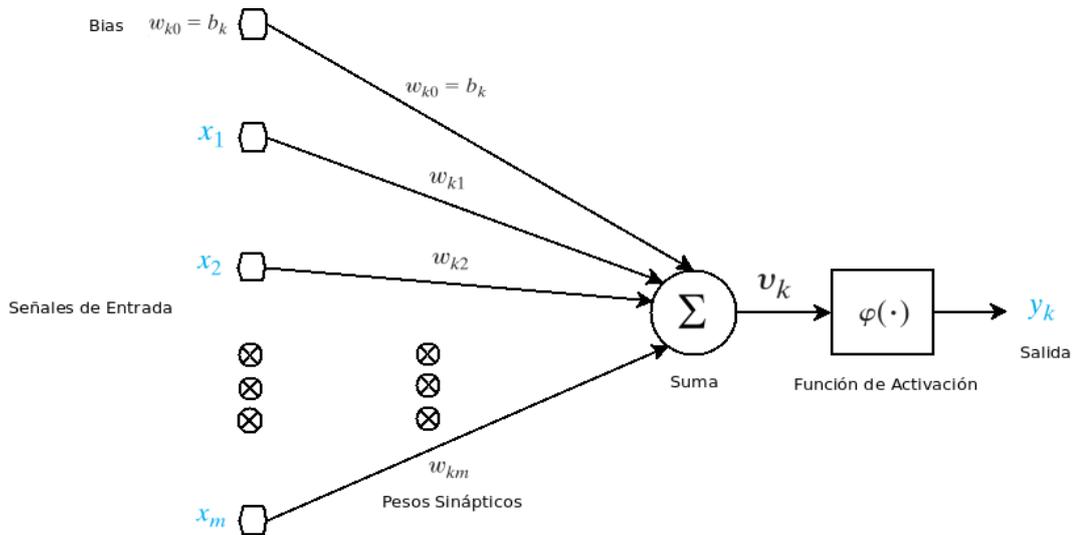


Figura 6.6: Modelo de neurona “k”, no lineal incluyendo el bias como una entrada. Fuente: Adaptado de Haykin (2009).

El bias tiene el efecto de incrementar (bias positivo) o disminuir (bias negativo) la entrada de la función suma en la función de activación, dando a la red una mayor libertad para el ajuste de los pesos de cada variable, dando más flexibilidad a una RNA.

- *Función de Activación:* sirve para evitar el incremento progresivo de los valores de salida en las capas de una RNA, limitando así la salida de la neurona, permitiendo determinado rango de la señal de salida para sumar valores finitos, siendo esta representada por φ . Dependiendo de la función utilizada puede activar o no la salida de una neurona en base a un valor de entrada “X”. Después de pasar por la función de activación la salida de la neurona (Y_k), que es dada por la ecuación 6.4.

$$Y_k = \varphi(v_k) \tag{6.4}$$

Las funciones de activación pueden ser lineales o no lineales, dependiendo de la función utilizada en la red. La próxima sección trata de las funciones de activación de forma detallada.

6.3.1. Funciones de Activación

A partir del modelo de neurona artificial propuesto por [McCulloch and Pitts \(1943\)](#), a lo largo de los años se desarrollaron otros modelos que permitieron la producción de una salida, no necesariamente cero o uno, y con distintas funciones de activación [Braga \(2000\)](#). De este modo las funciones de activación de una neurona definen la salida de una neurona en base a una entrada dada a la red.

La función de activación de una neurona puede ser del tipo lineal o no lineal. Su función principal es hacer una transformación del valor producido por el campo inducido de la neurona, y enviarlo a una próxima capa de neuronas o como resultado de una red, dependiendo de la arquitectura utilizada y de la posición específica de la neurona. Normalmente los rangos de salida de esta capa están entre $[0,1]$ o $[-1,1]$ dependiendo de la función de activación utilizada.

Las funciones de activación son imprescindibles para resolver problemas no lineales, ya que una red neuronal sin una función de activación es un modelo de regresión lineal, lo que puede ser verificado en la sección anterior, sobre el modelo de neurona artificial. A continuación son presentados los principales tipos de funciones de activación.

- *Función de Paso*: es la más simple de todas las funciones de activación. Es basada en un clasificador que tiene la neurona activada o no activada (binario). La regla de activación es presentada a continuación.

$$\varphi(v_k) = \begin{cases} 1, v_k \geq 0 \\ 0, v_k < 0 \end{cases}$$

Esta función es conocida en la matemática como función de Heavside, y en las redes neuronales como modelo de McCulloch, [Haykin \(2009\)](#). Es una función útil para crear un clasificador binario (sí o no) para una única clase, teniendo como valores de salida 0 o 1. Por tener un gradiente cero, para redes neuronales del tipo retropropagación este tipo de función de activación no es útil, visto que en retropropagación los gradientes son usados para ajustar los parámetros libres de la red, y en este caso siendo cero, no aportaría en este sentido.

La figura [6.7](#) muestra gráficamente la salida de una función de paso, con sus valores característicos de salida, cero y uno.

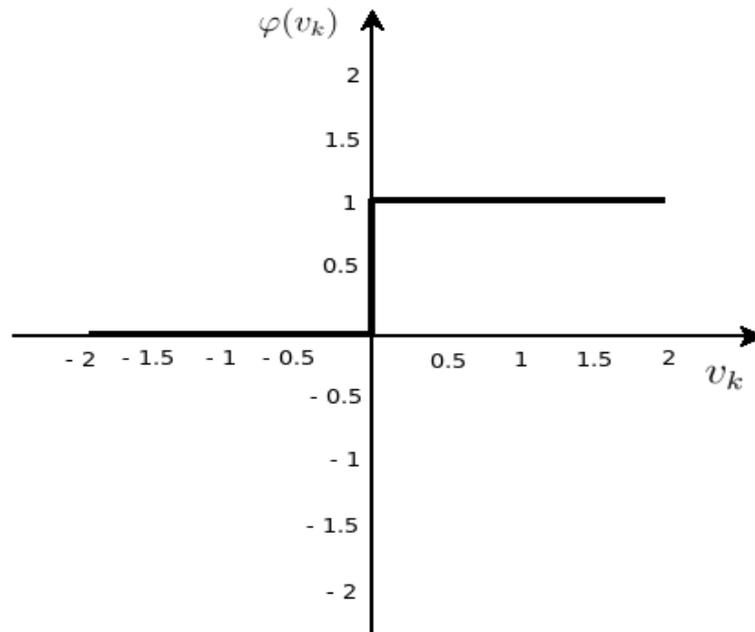


Figura 6.7: Representación de una función de paso. Fuente: Adaptado de [Haykin \(2009\)](#).

- *Función Lineal:* la función lineal puede ser de dos tipos: función identidad o lineal por tramos. Ambas variaciones aplican sobre el valor del campo inducido de la neurona una transformación lineal. La regla de activación de una función identidad es presentada en la ecuación 6.5, donde “a” es un coeficiente.

$$\varphi(v_k) = v_k * a \tag{6.5}$$

A su vez, la a regla de activación de una función lineal por tramos es presentada a continuación.

$$\varphi(v_k) = \begin{cases} 1, & v(k) \geq \frac{1}{2} \\ v(k), & \frac{-1}{2} < v(k) < \frac{1}{2} \\ -1, & v(k) \leq \frac{-1}{2} \end{cases}$$

La derivada de una función lineal es constante, esto significa que no depende del valor de entrada “ v_k ”. Esto significa que para esta función el gradiente sería el mismo, lo que para una función del tipo retropropagación, en una capa

oculta no sería útil. Esta función puede ser utilizada para tareas simples como clasificación de dos clases, u otros problemas que no exijan complejidad. Tiene sus salidas entre el rango de $[-1,1]$.

La figura 6.8 muestra gráficamente la salida de una función lineal de tipo identidad (a la izquierda) y una función lineal por tramos (a la derecha).

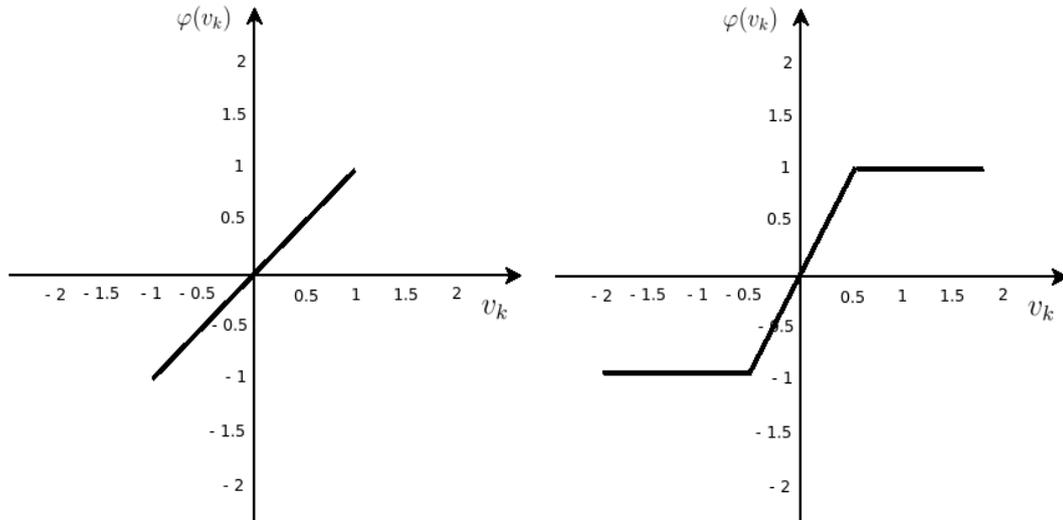


Figura 6.8: Representación de una función identidad (izquierda) y función por tramos (derecha). Fuente: Adaptado de Braga (2000).

- *Sigmoide o Función Logística:* Es una función no lineal, lo que implica que la salida de la neurona es no lineal. La función varía en un rango $[0,1]$ y tiene un formato S. La ecuación 6.6, presenta la función sigmoide.

$$\varphi(v_k) = \frac{1}{1 + e^{-\alpha v_k}} \quad (6.6)$$

En la ecuación 6.6, el parámetro α representa la pendiente de la función sigmoide, donde al variar este parámetro, se obtiene funciones sigmoides con distintas pendientes, Haykin (2009).

La función sigmoide tiene como limitación que los valores de los gradientes son pequeños, cercanos a cero. Esto se da porque la salida de una sigmoide varía en el rango $[0,1]$. Es una función no simétrica y diferenciable, o sea, admite derivadas en cualquier dirección, siendo útil para el método de retropropagación por ejemplo.

La figura 6.9 muestra gráficamente la salida de una función sigmoide, con

sus valores dentro del rango cero y uno.

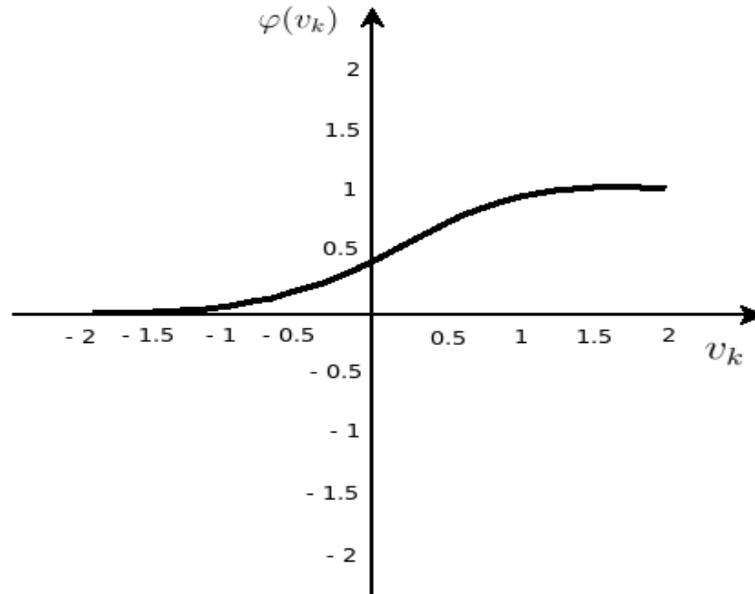


Figura 6.9: Representación de una función sigmoide. Fuente: Adaptado de [Haykin \(2009\)](#).

- *ReLU (Unidad Lineal Retificada)*: es una función no lineal, lo que significa que se puede retropropagar sus errores hacia atrás para ajustar los parámetros libres de una red, del tipo multicapa por ejemplo. Tiene como característica principal no activar todas las neuronas al mismo tiempo, lo que significa que una entrada negativa es convertida en cero, siendo la neurona no activada. Esto permite que la red sea más eficiente y fácil para el cómputo. La regla de activación de la función ReLU es presentada a continuación.

$$\varphi(v_k) = \begin{cases} v_k, & v_k \geq 0 \\ 0, & v_k < 0 \end{cases}$$

La función ReLU es muy parecida a la función identidad, excepto que cuando los valores de v_k son menores que cero, la función produce cero en su dominio. Tiene como principal problema que los gradientes son 0 para $v_k < 0$, lo que hace con las neuronas sean desactivadas en esa región.

Para resolver este problema la función ReLU tiene una variación, conocida como Leaky ReLU, que la define un pequeño componente lineal a los valores de $\varphi(v_k) < 0$. La regla de activación de la función Leaky ReLU es presentada a continuación, donde α es un coeficiente lineal.

$$\varphi(v_k) = \begin{cases} v_k, & v_k \geq 0 \\ \alpha v_k, & v_k < 0 \end{cases}$$

La función Leaky ReLU tiene como principal ventaja remover el gradiente cero, siendo el valor del coeficiente un valor pequeño, aproximado al 0.01.

La figura 6.10 muestra gráficamente la salida de una función del tipo ReLU (a la izquierda) y una función lineal por tramos (a la derecha).

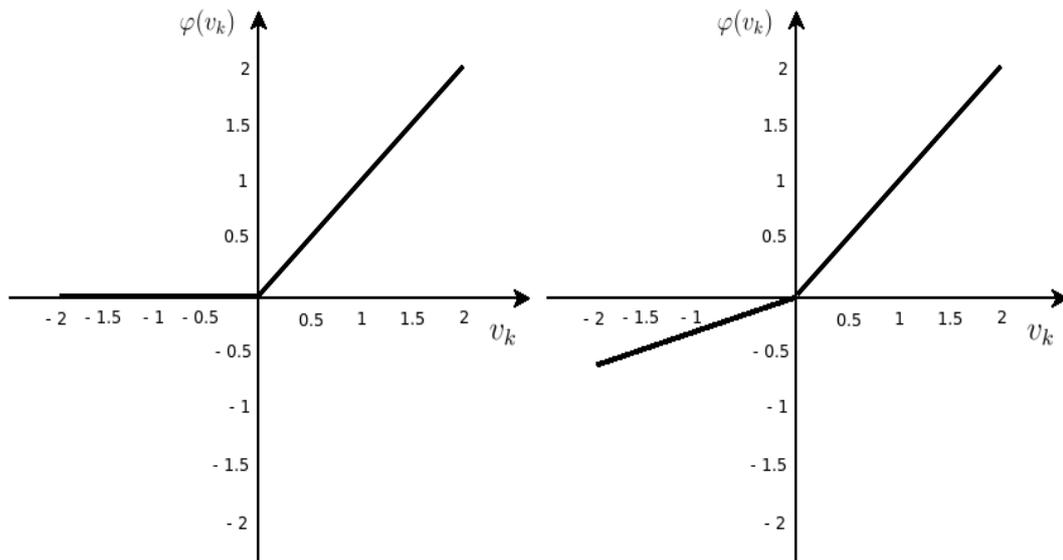


Figura 6.10: Representación de una función ReLU (izquierda) y función Leaky ReLU (derecha). Fuente: Propio Autor.

- *Tangente hiperbólica:* Es una función no lineal similar a la función sigmoide, que varía en el rango $[-1,1]$ y tiene un formato de “S” en su función, así como la sigmoide. La función tangente hiperbólica se aproxima bastante de la función identidad, y por del tipo no lineal es bastante utilizada en redes multicapa y con algoritmo de entrenamiento de retropropagación. La regla de activación de la función tangente hiperbólica es presentada a continuación, en la ecuación 6.7.

$$\varphi(v_k) = \frac{2}{1 + e^{-2v_k}} - 1 \quad (6.7)$$

La figura 6.11 muestra gráficamente la salida de una función tangente hiperbólica.

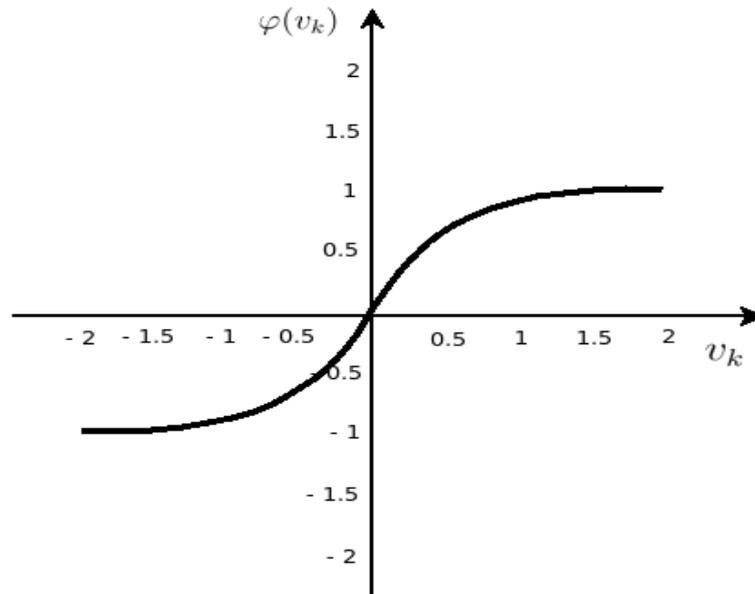


Figura 6.11: Representación de una función tangente hiperbólica. Fuente: Propio Autor.

La función tangente hiperbólica es continua y diferenciable en todo el rango $[-1,1]$, además de ser simétrica en relación al cero. Es muy utilizada para la resolución de problemas de naturaleza no lineal, con uso de redes neuronales artificiales.

6.4. Arquitecturas de RNA

Una única neurona es insuficiente para resolver los problemas en la práctica, así que las redes neuronales artificiales frecuentemente son diseñadas con un gran número de neuronas dispuestas en capas. El modo con que son conectadas las neuronas constituye una importante información para la decisión del uso de determinada red neuronal, [Yadav \(2004\)](#). Según [Haykin \(2009\)](#), el modo con que las neuronas de una red están estructuradas está íntimamente ligado al tipo de algoritmo de entrenamiento a ser utilizado. La disposición de las neuronas en una red neuronal determina cómo se hacen los ajustes de los parámetros libres (pesos sinápticos y bias) y también su arquitectura.

En esta sección se presentan tres arquitecturas que son comúnmente utilizadas: redes de capa única y redes multicapa, siendo que cada una está orientada a resolver distintos tipos de problemas. Redes neuronales de capa única solo pueden resolver problemas linealmente separables, a su vez, las redes recu-

rentes son apropiadas para resolver problemas que involucran procesamiento temporal (series temporales), Braga (2000). Las redes multicapa han sido utilizadas para resolver distintos problemas de naturaleza no lineal.

La red multicapa fue la arquitectura utilizada para el desarrollo de este trabajo, así que es presentada con mayor detalle, en la sección 6.4.2.

6.4.1. Redes de Capa Única

Una red de capa única está compuesta por los nodos, los cuales son los vectores que representan las variables de entrada y una capa de salida de “n” neuronas. En este tipo de red neuronal, las conexiones son estrictamente hacia adelante Haykin (2009). La figura 6.12 presenta como están dispuestas las neuronas en una capa de este tipo.

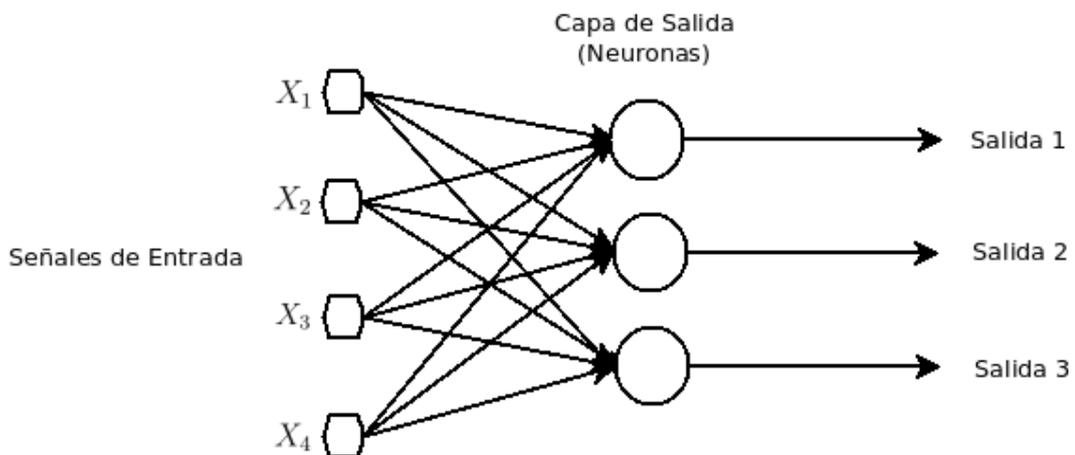


Figura 6.12: Arquitectura típica de una red neuronal de capa única.

En una red de capa única, tener las conexiones hacia adelante significa que la salida de una neurona “k” no puede ser utilizada como entrada en otras neuronas de la misma capa, Braga (2000). Comúnmente estas conexiones son denominadas “feedforward”.

6.4.2. Redes Multicapa

Una red multicapa está dividida estructuralmente en tres partes principales: los nodos (vectores que representan las variables de entrada), una o más capas de neuronas ocultas y una capa de salida con una o más neuronas. Este tipo de conexión es comúnmente denominada “multilayer”.

La figura 6.13 presenta un modelo genérico una red multicapa, con cuatro variables de entrada, una capa oculta con tres neuronas y una capa de salida con dos neuronas.

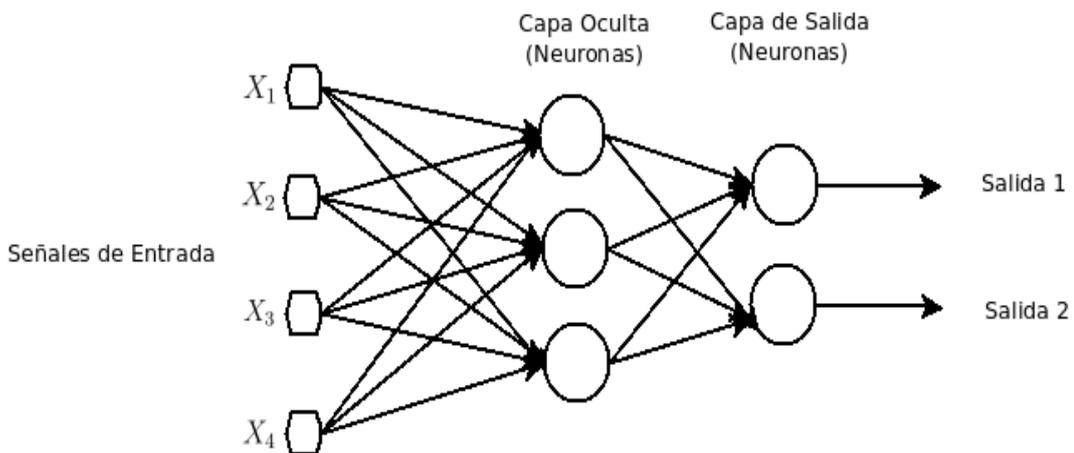


Figura 6.13: Esquema de una RNA multicapa.

En este tipo de red las señales de entrada son propagadas hacia adelante en la red (sentido de la izquierda hacia la derecha de la figura 6.13), siendo comúnmente denominadas “feedforward” en inglés, o prealimentada.

Según Haykin (2009), una red multicapa se distingue de una RNA de capa única, por tres características.

- El modelo de cada neurona incluye una función de activación no lineal, normalmente una función sigmoide.
- Contiene una o más capas de neuronas ocultas, lo que permite a la RNA resolver problemas no lineales.
- Alto grado de conectividad determinado por las sinapsis de la red.

Una red neuronal de tipo multicapa presenta dos tipos de señales, que son las señales funcionales (propagación hacia adelante) y las señales de errores (propagación hacia atrás). Una señal funcional sigue la regla de propagación de las RNA, donde todas las entradas y sus pesos sinápticos asociados se propagan en la red, resultando en una señal de salida en la terminal de salida de una red neuronal artificial.

A su vez, las señales de error se originan a partir de la diferencia de la

señal de salida estimada por la de la red y la señal objetivo. El valor resultante de esta diferencia se propaga hacia atrás, buscando ajustar por iteraciones los parámetros libres de la red (pesos sinápticos y bias), de modo a disminuir la diferencia entre la señal de salida estimada y la señal objetivo.

Las neuronas ocultas o de salida de una red neuronal multicapa son proyectadas para realizar dos cálculos principales, que son el cálculo de la señal funcional de la red y del vector gradiente, lo cual es necesario para que se realice la retropropagación en una red multicapa.

Las redes multicapa han sido muy utilizadas para resolver problemas complejos de distintas áreas de conocimiento. Comúnmente este tipo de red es aplicado a partir de entrenamientos supervisados (a partir de entrenamiento con información histórica de los datos objetivo), donde se destaca el uso del algoritmo de entrenamiento denominado “retropropagación de errores” (o del inglés, *backpropagation*), el cual está basado en la regla de aprendizaje por corrección de errores. La sección siguiente sobre los algoritmos de entrenamiento, muestra con detalles el algoritmo de retropropagación de errores, el cual fue utilizado para el desarrollo de este trabajo de tesis.

6.4.3. Redes Recurrentes

Las redes recurrentes tienen como características principales la realimentación de los nodos de entrada con las salidas de neuronas de la capa de salida y la aplicación de desfases en estas realimentaciones. Pueden ser estructuradas en capa única o multicapa. Para una red recurrente de capa única las salidas de cada neurona de la capa de salida realimentan las otras neuronas de la misma capa, pero no hacen una auto-realimentación.

A su vez, en una red recurrente con una capa de neuronas ocultas, cada neurona de esta capa hace una realimentación en la red como si fuera nuevas entradas. Así que la salida de una neurona, produce una nueva “entrada” en la red, entrada esta que realimenta toda la red, incluso a la neurona propia que generó este dato (auto-realimentación). Según [Yadav \(2004\)](#), una red recurrente con neuronas ocultas, es particularmente útil para resolver problemas donde la solución depende no solo en las entradas actuales, sino de todas las entradas anteriores. La estructura recurrente con sus realimentaciones y desfases en cada realimentación resulta un red con comportamiento dinámico y no lineal [Haykin \(2009\)](#).

La figura 6.14 presenta un modelo genérico una red recurrente de estructura capa única (a la izquierda) y un modelo genérico de una red recurrente con neuronas ocultas (a la derecha).

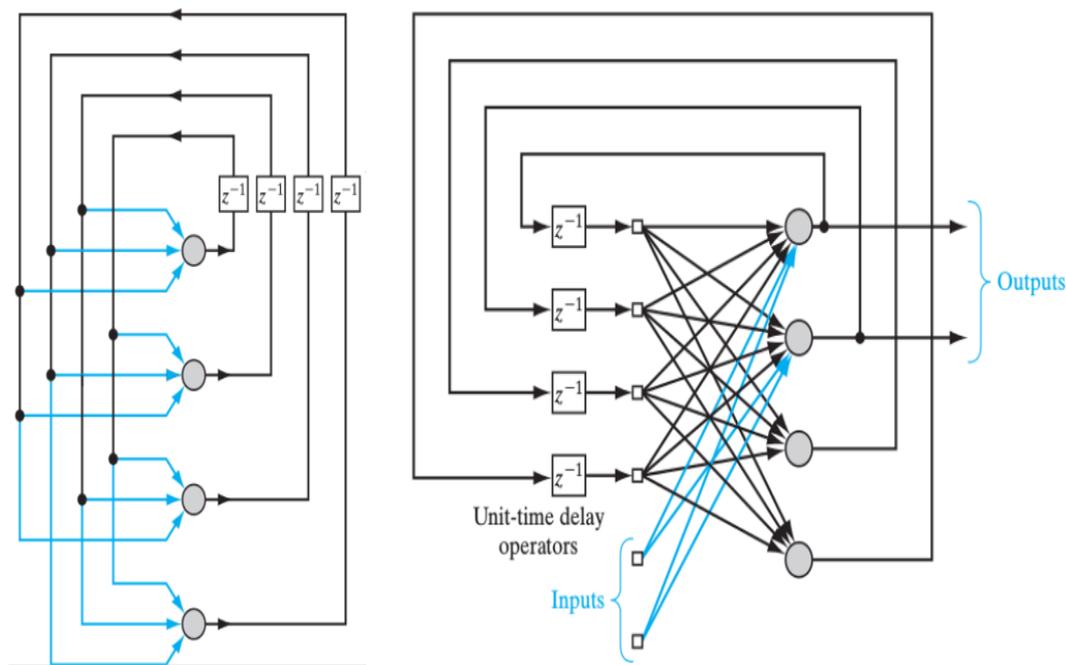


Figura 6.14: Modelo de una RNA recurrente de capa única (izquierda) y una RNA recurrente con neuronas ocultas (derecha), donde las conexiones en celeste em ambas estructuras, representan las realimentaciones de la red. Fuente: Haykin (2009).

6.5. Algoritmos de Entrenamiento

Una RNA tiene la capacidad de aprender a partir de ejemplos dados, por un proceso de aprendizaje. En el aprendizaje conexionista, no se busca obtener reglas, como en el abordaje simbólico de la inteligencia artificial, pero sí determinar la intensidad de las conexiones dentre las neuronas, Braga (2000).

Según Mendel and McLaren (1970), *el aprendizaje es un proceso por el cual los parámetros de una red neuronal son ajustados a través de una forma continuada de estímulo por el ambiente en el cual está operando la red, siendo el tipo específico de aprendizaje realizado definido por el modo particular de como ocurren los ajustes en los parámetros de la red.*

De los distintos métodos de ajuste de los parámetros libres de una red (pesos sinápticos y bias) es que surgen los distintos algoritmos de entrena-

miento de las redes neuronales artificiales. El método de entrenamiento de una red neuronal es básicamente dividido en dos tipos: aprendizaje supervisado y aprendizaje no supervisado.

- *Aprendizaje Supervisado*: En este método durante el entrenamiento de la red son presentadas entradas y las salidas deseadas. El objetivo principal es encontrar el mejor ajuste entre los parámetros libres de la RNA, de modo que, dada una entrada el resultado estimado por la red sea lo más cercano posible a la salida (dato objetivo).

El principal algoritmo de entrenamiento para este tipo de método es el aprendizaje por corrección de errores, el cual busca minimizar la diferencia entre la suma ponderada del producto de las entradas por los pesos sinápticos y la salida de la red. El error de salida de la red es representado como muestra la ecuación 6.8, donde (n) se refiere a una iteración numérica.

$$e(n) = d(n) - y(n) \tag{6.8}$$

En la ecuación 6.8, $e(n)$ representa el error de salida de la red, $d(n)$ la salida deseada (valor real de la variable objetivo en la iteración n) e $y(n)$ la salida estimada por la red. Del método de corrección de errores es que surge el principal algoritmo de entrenamiento de las RNA's multicapa, el de retropropagación de errores, el cual es detallado en la sección 6.5.1, por ser el algoritmo de entrenamiento utilizado para el desarrollo de este trabajo.

Un caso particular del método de aprendizaje supervisado es el aprendizaje por refuerzo. En este tipo de aprendizaje, durante la realimentación de la red es informada si la respuesta de la red está correcta o errada, pero no la magnitud del error entre los valores estimados y la salida deseada.

- *Aprendizaje No Supervisado*: En este método no son presentados a la red los datos objetivo durante el proceso de entrenamiento, o sea, durante el entrenamiento la red adquiere aprendizaje solamente en base a datos entrada.

Braga (2000), describe que “a pesar de la semejanza entre el aprendizaje supervisado y el aprendizaje de los seres humanos, muchos de los sistemas biológicos ocurren a través del aprendizaje no supervisado, como por ejemplo

las etapas iniciales de los sistemas de visión y audición”.

Entre los principales métodos para el aprendizaje no supervisado se destaca el aprendizaje de Hebb, presentado por [Hebb \(1949\)](#), que se caracteriza por las sinapsis entre dos neuronas activas sean más fuertes, y sinapsis entre neuronas no activas son débiles o desaparecen en la red.

Un tipo específico de aprendizaje no supervisado es el aprendizaje por competición, donde dada una entrada, las neuronas compiten entre ellas para que sean activadas y de este modo tener su salida activada y sus pesos sinápticos actualizados.

A continuación es presentada de forma detallada el algoritmo de entrenamiento de retropropagación de errores.

6.5.1. Retropropagación

El aprendizaje por retropropagación de errores consiste en dos etapas, que son la propagación (cálculos hacia adelante en la estructura de la red) y la retropropagación (cálculos hacia atrás en la estructura de la red). Un concepto importante a ser introducido para explicar el funcionamiento de la retropropagación son las “épocas”. Una época es cada iteración de la RNA por los datos de entrada, en que hay un ajuste de variables, lo cual se puede hacer después de la presentación de datos de entrada individuales o por conjunto.

En la propagación la señal de un vector de entrada se propaga hacia adelante siguiendo la regla de propagación de una neurona artificial. Esta propagación se da capa por capa hasta producir un vector de salida estimado por la red. Durante este proceso el peso de las neuronas son fijos. En la etapa de retropropagación, los parámetros libres de la red, que son los pesos sinápticos (W_{ji} , W_{kj}) y bias (b_k , b_j), son ajustados de acuerdo a la regla de corrección de errores. Este ajuste se da a partir del cálculo en la capa de salida de la red de la señal de error, la cual se propaga hacia atrás contra las direcciones de las sinapsis. Este ajuste de los pesos sinápticos se hace por un proceso numérico iterativo, hasta llegar a un error “e”, entre la salida de la red y los datos objetivo que sea lo menor posible respetando los criterios de parada, como el número máximo de épocas (iteraciones) por ejemplo.

Para explicar el proceso matemático del algoritmo de retropropagación de errores, la figura [6.15](#) presenta un esquema con señales provenientes de una capa oculta, conectadas por sinapsis a una neurona “k” de la capa de salida

de una red neuronal multicapa.

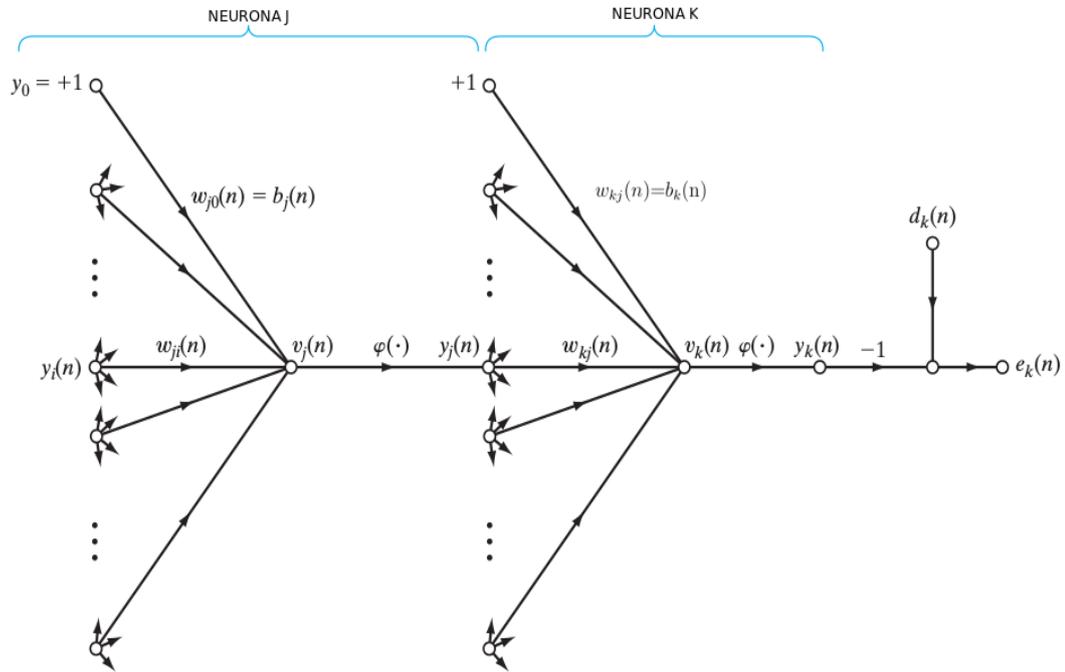


Figura 6.15: Esquema de una red multicapa con señales provenientes de una capa oculta, conectadas a una neurona “k” en la capa de salida. Fuente: [Haykin \(2009\)](#).

En la figura 6.15 la letra “n” representa las iteraciones de un proceso numérico. De las sinapsis de la capa oculta, se destacan la conexión de una neurona “j” a la neurona “k”, y la sinapsis correspondiente al bias de la neurona “j”, representado por $b_j(n)$. Se presenta la señal de entrada de la neurona “j” ($y_j(n)$) y su peso sináptico correspondiente a la conexión de las neuronas “j” y “k”, $w_{kj}(n)$. Para el bias del valor de entrada y_0 es igual a +1, y el peso sináptico corresponde al bias de la neurona “k”, representado por $w_{k0}(n) = b_k(n)$.

De modo de representar el proceso matemático, se considera de todas las entradas de la capa oculta, la proveniente de la neurona “j”. El campo local inducido de la neurona “k” es presentado por la ecuación 6.9, donde “m” en dicha ecuación representa el número de entradas (excepto la entrada del bias), aplicada a la neurona “k”.

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (6.9)$$

La señal de salida de la neurona “k” es presentada en la ecuación 6.10.

$$y_k(n) = \varphi(v_k(n)) \quad (6.10)$$

En la ecuación 6.10 la variable φ representa la función de activación de la neurona “k”, la cual para una red multicapa, comúnmente es no lineal y del tipo sigmoide. La señal de salida de la neurona “k”, representada por $y_k(n)$ es comparada con el vector objetivo $d_k(n)$, y así se obtiene el error $e_k(n)$ del proceso de propagación, lo cual es presentado en la ecuación 6.11.

$$e_k(n) = d_k(n) - y_k(n) \quad (6.11)$$

A partir del cálculo de error ($e_k(n)$) se ajustan los pesos sinápticos de las neuronas de la red, de modo a disminuir el valor del error a cada iteración, siendo a partir de este proceso empieza la etapa de retropropagación. El ajuste de los pesos sinápticos se logra a partir de la minimización de una función de costo, representada por $\xi(n)$. Dicha función es calculada conforme presentado en la ecuación 6.12, la cual representa la energía instantánea del error para la neurona “k” en la iteración “n”.

$$\xi(n) = \frac{1}{2} e_k^2(n) \quad (6.12)$$

Sumando la energía instantánea del error para todas las neuronas de la capa de salida, el total de la energía instantánea del error se presenta en la ecuación 6.13, donde C representa todas las neuronas de la capa de salida de la red.

$$\xi(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (6.13)$$

El algoritmo de retropropagación aplica una corrección $\Delta w_{kj}(n)$ al peso

sináptico $w_{kj}(n)$. Dicha corrección es proporcional a la derivada parcial de $\frac{\partial \xi(n)}{\partial w_{kj}(n)}$, la cual es presentada en la ecuación 6.14.

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = \frac{\partial \xi(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial w_{kj}(n)} \quad (6.14)$$

La derivada parcial $\frac{\partial \xi(n)}{\partial w_{kj}(n)}$ representa un factor de sensibilidad, la cual determina la dirección de búsqueda en el espacio de pesos, para el peso sináptico w_{kj} .

Aplicando la diferencial del total de la energía instantánea del error $\xi(n)$ en relación al error $e_k(n)$, como resultado es presentado en la ecuación 6.15.

$$\frac{\partial \xi(n)}{\partial e_k(n)} = e_k(n) \quad (6.15)$$

Diferenciando el error de la red $e_k(n)$ en relación a la señal de salida de la neurona “k” $y_k(n)$, tenemos como resultado lo presentado en la ecuación 6.16.

$$\frac{\partial e_k(n)}{\partial y_k(n)} = -1 \quad (6.16)$$

Diferenciando la señal de salida de la neurona “k” $y_k(n)$ en relación al campo local inducido de la neurona “k” $v_k(n)$, tenemos como resultado lo presentado en la ecuación 6.17.

$$\frac{\partial y_k(n)}{\partial v_k(n)} = \varphi'(v_k(n)) \quad (6.17)$$

Diferenciando el campo local inducido de la neurona “k” $v_k(n)$ al peso sináptico de la conexión entre la neurona “k” y “j” $w_{kj}(n)$, tenemos como resultado lo presentado en la ecuación 6.18.

$$\frac{\partial v_k(n)}{\partial w_{kj}(n)} = y_j(n) \quad (6.18)$$

Resolviendo estas diferenciales, la ecuación 6.14 resulta en la ecuación 6.19.

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = -e_k(n) \varphi'(v_k(n)) y_k(n) \quad (6.19)$$

La corrección en los pesos sinápticos $\Delta w_{kj}(n)$ aplicada a $w_{kj}(n)$ es definida por la regla delta, la cual es presenta en la ecuación 6.20.

$$\Delta w_{kj}(n) = -\eta \frac{\partial \xi(n)}{\partial w_{kj}(n)} \quad (6.20)$$

En la ecuación 6.20, el parámetro η se denomina tasa de aprendizaje de algoritmo de retropropagación. El signo negativo en la ecuación 6.20, indica una disminución del gradiente en el espacio de pesos sinápticos, de modo de reducir el valor de $\xi(n)$. Haykin (2009) formula la regla delta como: “*el ajuste realizado en un peso sináptico de una neurona es proporcional al producto del signo del error por la señal de entrada de la sinape en cuestión*”.

Sustituyendo la ecuación 6.19 en 6.20, resulta en la ecuación 6.21 presenta a continuación.

$$\Delta w_{kj}(n) = \eta \partial_k(n) y_i(n) \quad (6.21)$$

$\partial_k(n)$ es denominado gradiente local, y se calcula a partir de las ecuaciones 6.22, 6.23 y 6.24.

$$\partial_k(n) = \frac{\partial \xi(n)}{\partial v_k(n)} \quad (6.22)$$

$$\partial_k(n) = \frac{\partial \xi(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \quad (6.23)$$

$$\partial_k(n) = v_k(n)\varphi'_k(v_k(n)) \quad (6.24)$$

El gradiente local $\partial_k(n)$, presenta a la red las modificaciones necesarias en los pesos sinápticos. El cálculo del gradiente local presentado anteriormente para la neurona “k” $\partial_k(n)$, depende básicamente de dos condiciones. Si la neurona “k” es un nodo de salida o un nodo oculto. Siendo “k” un nodo de la capa de salida, la ecuación 6.24 representa la formulación necesaria para el cálculo del gradiente local.

En el caso de la neurona “k” en la capa de salida, el cálculo del gradiente local de esta neurona $\partial_k(n)$, es igual al producto de la derivada asociada a esta neurona $\varphi'_k(v_k(n))$ por la suma ponderada de los gradientes locales calculados para la próxima capa, que puede ser oculta o de salida, la cual está conectada con la neurona “k”. En este caso el cálculo del gradiente de la neurona “k” se representa por la ecuación 6.25.

$$\partial_k(n) = \varphi_k(v_k(n)) \sum_l \varphi_l(n)w_{lk}(n) \quad (6.25)$$

En la ecuación 6.25, “k” es una neurona de la próxima capa (hacia adelante en la red).

El entrenamiento en resumen lo que hace es:

- Atribuye pesos aleatorios a las variables de entrada de la red.
- Ejecuta la simulación.
- Compara la salida estimada por la red con los datos reales (target).
- Modifica los pesos sinápticos de modo a buscar el menor error posible entre los datos estimados y los datos reales.
- Repite el proceso de simulación (entrenamiento) hasta llegar a un error

mínimo o número máximo de épocas (interacciones) definidos como parámetros para el entrenamiento de la red.

6.6. Métricas de Evaluación

Para optimizar el uso de las redes neuronales artificiales, algunas métricas estadísticas son utilizadas para evaluar el proceso de aprendizaje de una RNA, y consecuentemente su capacidad de pronosticar las variables de interés.

Durante el entrenamiento de una RNA, se utilizan dos criterios de parada principales, que son el error de salida de la red y el número máximo de épocas (presentación de todos los patrones de entrenamiento de una red, corresponde a una época). Para el proceso de entrenamiento, los datos de entrenamiento son divididos en tres grupos: entrenamiento, validación y test, [Haykin \(2009\)](#). De acuerdo a [Haykin \(2009\)](#), el grupo de entrenamiento se refiere a los datos en que la RNA usará para adquirir el aprendizaje, a partir del ajuste de los pesos sinápticos, siendo preferible que este conjunto de datos sea en mayor número comparado a los datos de validación y test. Los datos de validación son utilizados para determinar el criterio de parada del entrenamiento y otros ajustes, para evitar problemas de sobreaprendizaje (overfitting), que es cuando la red memoriza los datos de entrenamiento, lo que hace que la misma no tenga capacidad de generalizar, de identificar patrones, frente a nuevos datos de entrada distintos a los utilizados en el entrenamiento. Los datos de test, son utilizados luego de la etapa de entrenamiento y sirven para evaluar todo el proceso de entrenamiento.

Una característica muy importante del proceso de entrenamiento es que cuanto mayor sea el número de datos utilizados para entrenar un modelo de RNA (considerando datos de entrenamiento, validación y test), mayor es la capacidad de la RNA de reconocer patrones frente a nuevos datos de entrada, y consecuentemente mayor la capacidad de pronosticar con una buena exactitud.

La figura 6.16, presenta para una red neuronal artificial de tipo multicapa, una gráfica que determina el mejor criterio de parada de entrenamiento de una RNA, así como los puntos donde la RNA no tiene capacidad de generalizar debido a un sub entrenamiento (underfitting), o por un sobreentrenamiento (overfitting). Cabe resaltar que en un caso de sobreentrenamiento (overfitting), la red memoriza los datos de entrenamiento, y así pierde la capacidad de identificar patrones.

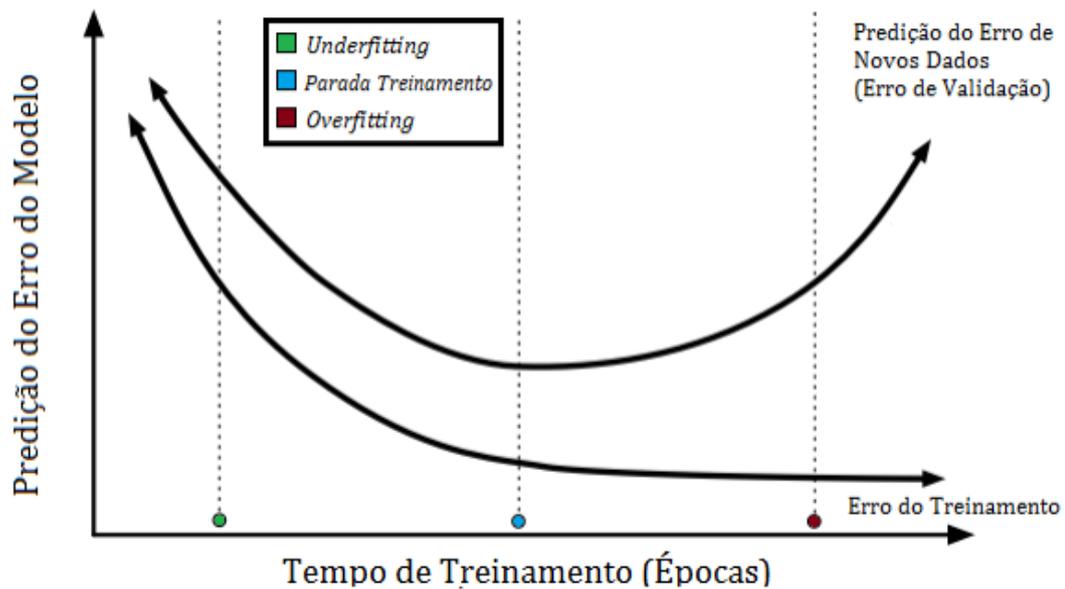


Figura 6.16: Ejemplo de errores en entrenamiento en una red multicapa. Fuente: Filho (2016).

La figura 6.16, muestra dos curvas, que son el error de entrenamiento (curva inferior) y el error de validación (curva superior). En el punto de underfitting (punto verde), los errores de ambas las curvas son altas, así que una parada del entrenamiento en este caso, es precipitado, visto que la red neuronal no fue capaz de identificar patrones debido a una parada temprana. En caso de overfitting (punto rojo), el error del conjunto de entrenamiento es bajo, pero el error del conjunto de datos de la validación es alto, lo que significa que la red hizo una memorización de los datos de entrenamiento, y no tuvo la capacidad de identificar patrones frente a nuevos datos que no estaban presentados en el conjunto de entrenamiento. El punto azul, muestra la ubicación en que el entrenamiento debe ser finalizado, pues es el punto de menor error de los datos de validación, y a partir de este punto los errores de dicho conjunto de datos empieza a aumentar, lo que muestra que en una red con sobreentrenamiento, el modelo pierde la capacidad de generalización, de identificar nuevos patrones. Los puntos mencionados anteriormente son distintos para cada problema, pero se mantiene el mismo orden. No existe un valor único de la cantidad de épocas ideal para todos los diferentes problemas, siendo que definir la cantidad de épocas para un problema no es una tarea trivial.

Una métrica estadística muy utilizada para cuantificar la magnitud del error medio de un modelo de pronóstico es el Error Medio Absoluto (Mean

Absolut Error (MAE), del inglés). De acuerdo a [Fox \(1981\)](#), dicha métrica es un método preciso y robusto, como medida de los modelos numéricos en reproducir la realidad. [Willmot \(2005\)](#), describe que el MAE como la medida de error más apropiada que el RMSE (root mean square error), debido que el MAE representa un conjunto de errores, el error medio. La ecuación 6.26, presenta el cálculo de dicho parámetro estadístico, lo cual se presenta en término absoluto.

$$MAE = \frac{1}{N} \sum |\theta_{sim} - \theta_{obs}| \quad (6.26)$$

En la ecuación 6.26, “ N ” representa el número de datos, θ_{sim} son los valores simulados/pronosticados por el modelo y θ_{obs} son los datos reales.

Otro parámetro estadístico muy utilizado es la correlación lineal, la cual determina si existe o no alguna relación entre dos variables analizadas. El parámetro que cuantifica la correlación lineal, es conocido como coeficiente de correlación lineal de Pearson “ r ”, cuyo valor de encuentra entre -1 y 1. La ecuación 6.27 presenta el necesario para determinar el coeficiente de correlación lineal de Pearson.

$$-1 \leq r = \frac{Cov(X, Y)}{S_x S_y} \leq +1 \quad (6.27)$$

En base a la ecuación 6.27, un coeficiente positivo entre una variable “ x ” e “ y ”, significa una relación directa entre ambas, donde valores positivos de “ x ” estan asociados a un aumento de valores de “ y ”, siendo la misma tendencia válida para valores negativos de “ x ” e “ y ”. A su vez, cuando el coeficiente de correlación de Pearson es negativo, las variables tienen una relación inversa, donde el aumento del valor de “ x ” esta asociado a una disminución del valor de “ y ”, siendo válido lo mismo para el caso contrario.

El coeficiente de correlación lineal de Pearson es muy utilizado para ajustar datos por medio de una corrección lineal, denominada regresión lineal. En la regresión lineal se usa el coeficiente de Pearson, para multiplicar las entradas de modo a ajustar la nube de puntos de los valores simulados y los valores reales, siendo previamente utilizado un periodo de entrenamiento de dicho método mediante a datos históricos.

Capítulo 7

Metodología

7.1. Parques Eólicos y Torres de Mediciones Utilizadas para el Estudio

Para el presente trabajo se evalúan ocho modelos de pronósticos desarrollados, los cuales son en base al modelo numérico WRF-ARW+redes neuronales artificiales (WRF-RNA) y WRF-ARW+regresión lineal (WRF-RL). Los modelos en base al modelo WRF-RNA fue el modelo central del trabajo, y los modelos en base al WRF-RL fueron utilizados como una base para una comparación de evaluación del pronóstico.

Los modelos de pronósticos desarrollados fueron evaluados para un conjunto de 31 parques eólicos ubicados en territorio Uruguayo. Dichos parques tenían una base de datos de potencia media horaria, dentro del período del 1 de Junio 2016 03:00 AM UY hasta el 1 de Junio 2018 02:00 AM UY, totalizando dos años. El primer año de la base de datos (1 de Junio 2016 03:00 AM UY hasta el 1 de Junio 2017 02:00 AM UY) fue utilizado como periodo de entrenamiento para el modelo WRF-RNA, y como período para sacar coeficientes para el modelo WRF-RL. El periodo posterior, del 1 de Junio 2017 03:00 AM UY hasta el 1 de Junio 2018 02:00 AM UY fue utilizado para la evaluación de los pronósticos.

Además de los datos de potencia media horaria de cada uno de los 31 parques eólicos evaluados, se utilizaron para el mismo periodo, datos de velocidad media horaria del viento de 11 torres de mediciones, que están ubicadas cerca de los parques eólicos evaluados. Los datos de las torres fueron utilizados para evaluar si una corrección de la velocidad del viento del modelo WRF-ARW

via análisis cluster aportaba un mejor pronóstico para los modelos WRF-RNA y WRF-RL. La figura 7.1 presenta la distribución geográfica de cada uno de los parques eólicos en estudio (izquierda) y las torres de mediciones (derecha) utilizadas para la implementación del análisis cluster.

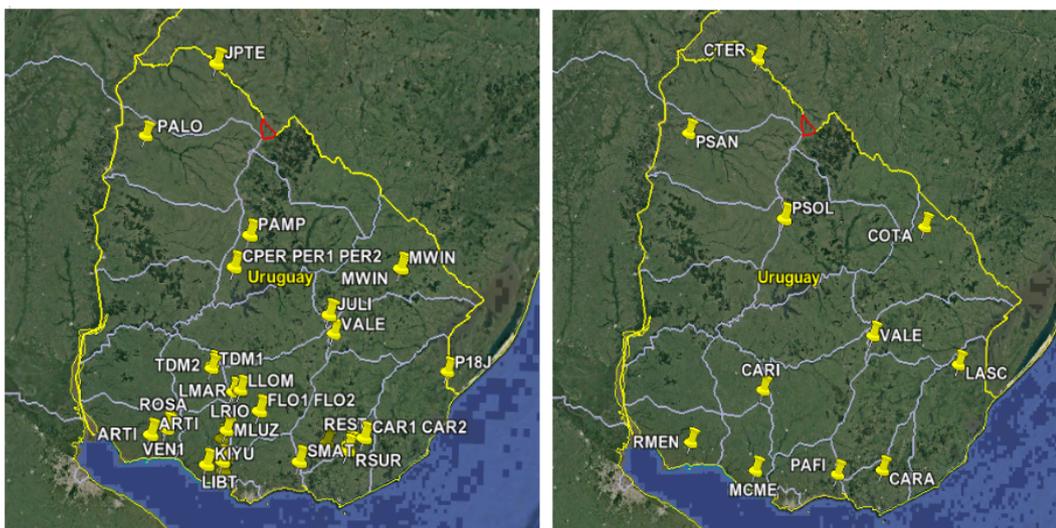


Figura 7.1: Parques eólicos (izquierda) y torres de mediciones (derecha) utilizadas para estudio.

En la base de datos de potencia media horaria, se hizo un preprocesamiento, con la finalidad de filtrar los datos que estaban en condiciones de restricciones operativas. En el sistema eléctrico Uruguayo se definen las restricciones operativas como las reducciones a la generación impuestas por ADME (Administración del Mercado Eléctrico) para la operación segura del sistema, [ADME \(2015\)](#). Los casos de restricciones operativas se aplican en los momentos en que, de no aplicarse la reducción de la generación total, esta superaría la demanda de Uruguay más la exportación de energía, que la operación del sistema Interconectado Nacional (SIN), estaría sujeta a una operación de riesgo.

Para los datos de velocidad horaria media del viento, provenientes de las torres de mediciones utilizadas en este trabajo, se hizo un filtro también, considerando los datos inválidos (por mala medición de los sensores) medidos por las torres.

La tabla 7.1 presenta los parques eólicos elegidos, con sus respectivas potencias nominales (MW), códigos de cuatro dígitos utilizados para identificar cada parque eólico así como los fabricantes y modelos de aerogeneradores instalados en cada parque eólico.

Tabla 7.1: Parques eólicos elegidos para el presente estudio.

Parque Eólico	Potencia (MW)	Código	Fabric. y Aero.
ARTILLEROS	65.1	ARTI	SUZLON S95
CARAPE I	50	CAR1	VESTAS V112
CARAPE II	40	CAR2	VESTAS V112
CUC. DE PERALTA	50	CPER	GAMESA G90
FLORIDA I	50	FLO1	NORDEX N117
FLORIDA II	50	FLO2	VESTAS V117
J. P. TERRA	67.2	JPTE	NORDEX N117
JULIETA	3.6	JULI	VESTAS V100
KENTILUX	17.2	KENT	VESTAS V90
KIYU	48.6	KIYU	VESTAS V112
LIBERTAD	7.7	LIBT	IMPISA V87
LUZ DE LOMA	20	LLOM	VESTAS V112
LUZ DE MAR	18	LMAR	VESTAS V112
LUZ DE RÍO	50	LRIO	VESTAS V112
MINAS I	42	MIN1	VESTAS V112
MARÍA LUZ	10	MLUZ	VESTAS V100
MELOWIND	50	MWIN	NORDEX N100
18 DE JULIO	10	P18J	VESTAS V100
PALOMAS	70	PALO	VESTAS V112
PAMPA	140	PAMP	NORDEX N117
PERALTA I	50	PER1	ENERCON E92
PERALTA II	50	PER2	ENERCON E92
R DEL ESTE	50	REST	GAMESA G90
RODRIGUEZ	10	RODR	VESTAS V100
ROSARIO	9	ROSA	VESTAS V100
R DEL SUR	50	RSUR	GAMESA G97
S. DE MATAOJO	10	SMAT	VESTAS V100
T. DE MACIEL I	50	TDM1	GAMESA G97
T. DE MACIEL II	50	TDM2	GAMESA G97
VALENTINES	70	VALE	GAMESA G114
VENTUS I	9	VEN1	VESTAS V100
TOTAL (SUMA)	1267,4	TOTAL (SUMA)	

Las torres de medición utilizadas para el análisis cluster, hicieron una corrección del *sesgo*¹ de la velocidad del viento, utilizando tres grupos cluster separados por velocidad baja, media y alta, donde en cada grupo habían 3 grupos cluster (total de 9 casos). El número de torres utilizadas fue 11, las

¹El sesgo o bias, en estadística, es la diferencia entre el valor estimado y el verdadero valor de la variable medida. Un sesgo positivo significa que el modelo sobreestima los valores en relación a los datos reales. A su vez, un sesgo negativo, significa que el modelo subestima los valores cuando comparado a los valores reales de la variable de interés.

cuales fueron: Caracoles (CARA), Colonia Arias (CARI), Colonia Otamendi (COTA), Colonia Terra (CTER), Lascano (LASC), Mc Meekan (MCME), Paloma Santa Rita (PSAN), Piedras de Afilas (PAFI), Piedra Sola (PSOL), Rosendo Mendoza (RMEN) y Valentines (VALE). La tabla 7.2 presenta la lista de torres de mediciones (por código) de la velocidad del viento, las alturas correspondientes de las medidas y los parques eólicos cercanos a cada torre.

Tabla 7.2: Torres de mediciones, alturas correspondientes de las medidas de cada torres y parques eólicos cercanos a cada una de las torres.

Torre	Altura de Med.	Parques Eólicos .
CARA	68.1	CAR1, CAR2, MIN1, REST, RSUR
CARI	83.2	FLO1, FLO2, LLOM, LMAR, LRIO, TDM1, TDM2
COTA	101.6	MWIN
CTER	99.3	JPTE
LASC	70.3	P18J
MCME	101.5	KENT, KIYU, LIBT, MLUZ, RODR
PSAN	99.3	PALO
PAFI	62.6	SMAT
PSOL	101.6	CPER, PAMP, PER1, PER2
RMEN	101.2	ARTI, ROSA, VEN1
VALE	91.7	JULI, VALE

7.2. Modelo Numérico WRF-ARW

Para la presente tesis fue utilizado el modelo numérico WRF-ARW versión 3.8.1. Se realizaron simulaciones con horizonte temporal de 72 horas (UTC). Para el análisis se descartaron las primeras 6 horas de la simulación a los efectos de eliminar el período de *spin-up*¹ del modelo. Del período restante [7-72] se utilizaron el horizonte de pronóstico entre [7-30] horas, lo equivalente a las 03:00 AM hasta las 02:00 AM (día posterior) de la hora local de Uruguay (UTC-3), o sea, un horizonte de 24 horas de pronóstico.

Todas las simulaciones se hicieron en base a datos gratuitos de condiciones de borde del modelo GFS (Global Forecasting System) de resolución 1 grado, lo que es equivalente a aproximadamente 111 Km de resolución (norte-sur, este-oeste) en las latitudes medias, como la que está ubicado Uruguay. La configuración espacial utilizada fue de un dominio centrado en territorio de

¹Spin-up es el tiempo que los modelos numéricos de circulación atmosférica necesitan para derivar un estado físico válido, después de una inicialización.

Uruguay, de resolución de 30 km (este-oeste, norte-sur) con 61 puntos de malla en sentido este-oeste y 55 puntos de malla en el sentido norte-sur. La proyección cartográfica utilizada fue Lambert Conformal y los datos con informaciones de topografía y uso del suelo fueron los de USGS. La figura 7.2 presenta el dominio utilizado para las simulaciones, con resolución espacial horizontal de 30 km.

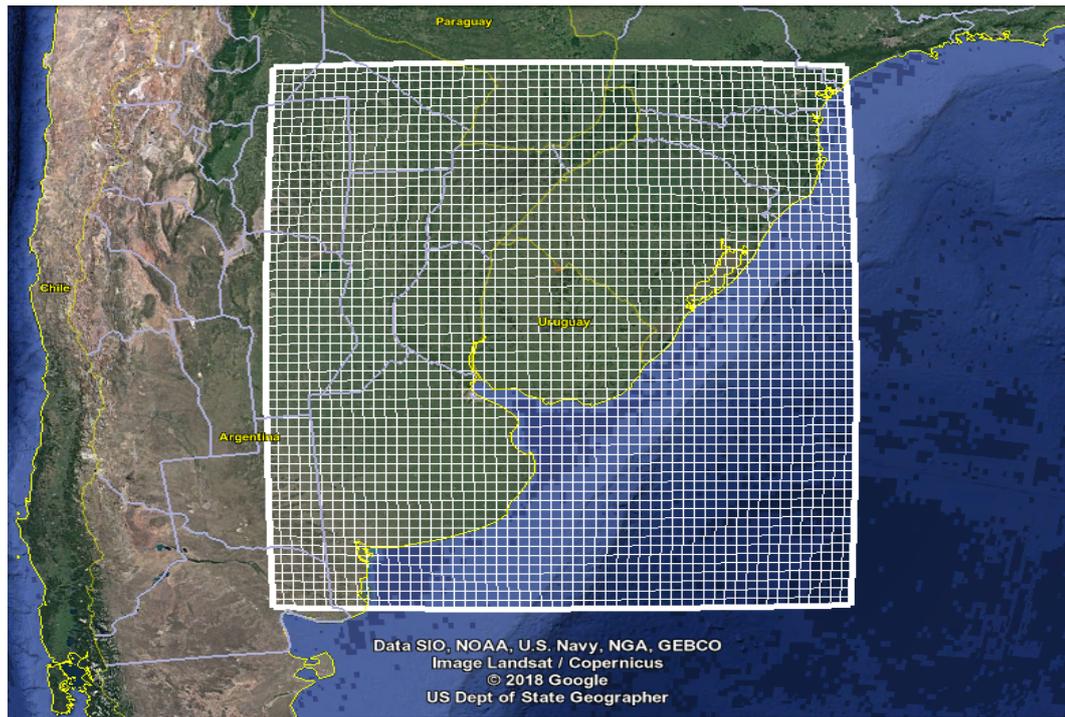


Figura 7.2: Discretización espacial con grilla computacional de resolución 30kmx30km centrada sobre Uruguay.

El modelo fue configurado con 30 niveles verticales (por defecto en el modelo). Fueron realizadas simulaciones con dos parametrizaciones físicas de capa límite atmosférica y capa de superficie.

Para todo el período simulado fue habilitada la opción de nudging, la cual a cada 3 horas de simulaciones el modelo incorporando los datos del modelo GFS dentro de la grilla. De las variables físicas pronosticadas por el modelo WRF-ARW que fueron utilizadas como entrada al pronóstico fueron la velocidad del viento, la densidad del aire y la dirección del viento, siendo todas estas variables a aproximadamente 100 metros de altura de la superficie y para cada punto asociado a las de coordenadas geográficas de cada parque eólico.

Las parametrizaciones físicas utilizadas en el modelo WRF-ARW son presentadas la tabla 7.3.

Tabla 7.3: Parametrizaciones Físicas utilizadas en el Modelo WRF-ARW.

Capa Límite Atmosférica	Mellor-Yamada-Janjic, Yonsei University
Microfísica	Lin Purdue
Cumulus (Nubes)	Kain-Fritsch
Radiación de Onda Corta	Dudhia
Radiación de Onda Larga	RRTM
Capa de la Superficie	Revised MM5, Eta Similarity
Suelo-Superficie	Unified Noah land-surface model

7.3. Configuración Cluster

El análisis cluster es una técnica utilizada para encontrar patrones ocultos o agrupaciones ocultas en un conjunto de datos. El método clustering utilizado fue el k-means [MacQueen \(1967\)](#), el cual es comúnmente utilizado para particionar automáticamente un conjunto de datos en “k” grupos [Wagstaff \(2001\)](#). El método de k-means, en resumen, centra el grupo inicial k y luego iterativamente asigna a cada distancia “d” un grupo de datos más cercanos [Wagstaff \(2001\)](#).

El método de análisis cluster fue utilizado para corregir posibles errores sistemáticos (sesgos) en el vector del ciclo diario de la velocidad media diaria del viento, a aproximadamente 100 metros de altura estimado por el modelo WRF-ARW (altura del eje de los aerogeneradores). Para aplicarlo fue necesario identificar torres cercanas a los parques eólicos en estudio y aplicar el método para el período de entrenamiento (1 año), donde se dividieron los datos de velocidad del viento de las torres primero por el valor de la velocidad media diaria (alta, media y baja velocidad del viento), siendo los umbrales definidos en base a la media anual de la velocidad del viento y la desviación estándar de la velocidad del viento de los datos provenientes del modelo WRF-ARW. Las ecuaciones [7.1](#), [7.2](#) y [7.3](#), a seguir muestran como fueron definidos los umbrales de baja, media y alta velocidad del viento respectivamente.

$$\bar{V}_{diariawrf} < (\bar{V}_{anualtorre} - 0.5\sigma_{anualtorre}) \Rightarrow (baja) \quad (7.1)$$

$$(\bar{V}_{anualtorre} - 0.5\sigma_{anualtorre}) \leq \bar{V}_{diariawrf} \leq (\bar{V}_{anualtorre} + 0.5\sigma_{anualtorre}) \Rightarrow (media) \quad (7.2)$$

$$\bar{V}_{diaria\text{wrf}} > (\bar{V}_{anual\text{torre}} + 0.5\sigma_{anual\text{torre}}) \Rightarrow (alta) \quad (7.3)$$

Donde:

\bar{V}_{anual} = Velocidad media anual del periodo de entrenamiento (m/s).

\bar{V}_{diaria} = Velocidad media del ciclo diario del vector velocidad (m/s).

σ = desviación estándar de la velocidad del viento (m/s).

Los umbrales de baja, media y alta velocidad media horaria del viento presentados en la ecuaciones 7.1, 7.2 y 7.3 fueron definidos en base a valores de velocidad media del vector ciclo diario. Cada umbral definido tuvo 3 agrupaciones (C11, C12, C13 (clusters de baja velocidad), C21, C22, C23 (clusters de media velocidad), C31, C32, C33 (clusters de alta velocidad), totalizando 9 agrupaciones. Cada una de las tres agrupaciones de cada cluster tuvieron por lo menos 20% de los días referentes al total de cada cluster, teniendo así una distribución representativa por casos.

La tabla 7.4 presenta la lista de torres de mediciones de la velocidad del viento, las alturas correspondientes de las medidas y los parques eólicos cercanos a cada torre.

Tabla 7.4: Torres de mediciones, alturas correspondientes de las medidas de cada torres y parques eólicos cercanos a cada una de las torres.

Torre	Altura de Med.	Parques Eólicos
CARA	68.1	CAR1, CAR2, MIN1, REST, RSUR
CARI	83.2	FLO1, FLO2, LLOM, LMAR, LRIO, TDM1, TDM2
COTA	101.6	MWIN
CTER	99.3	JPTE
LASC	70.3	P18J
MCME	101.5	KENT, KIYU, LIBT, MLUZ, RODR
PSAN	99.3	PALO
PAFI	62.6	SMAT
PSOL	101.6	CPER, PAMP, PER1, PER2
RMEN	101.2	ARTI, ROSA, VEN1
VALE	91.7	JULI, VALE

7.3.1. Técnicas de pronóstico

En el presente trabajo se analiza el desempeño de dos técnicas de pronóstico de potencia eólica (WRF-RNA y WRF-RL), que utilizan como entrada los pronósticos de las variables atmosféricas dadas por el modelo WRF-ARW. Las técnicas evaluadas toman como entrada las variables físicas que tienen influencia directa en la producción de potencia eólica.

Considerando que la potencia que un aerogenerador puede extraer del flujo de energía cinética está dado por la ecuación 7.4, donde ρ es densidad del aire (kg/m^3), v es la velocidad del viento en la altura del eje del aerogenerador (m/s), A es el área de la sección del barrido de las palas del aerogenerador (m^2), y C_P el coeficiente adimensional de potencia del aerogenerador (el cual depende del modelo de aerogenerador instalado).

$$P = C_P \frac{1}{2} \rho v^3 A \quad (7.4)$$

La ecuación 7.4 muestra cómo se calcula la potencia eléctrica para un aerogenerador, siendo que la potencia de un parque eólico se da por la suma de la potencia de sus aerogeneradores.

En un parque eólico la dirección del viento también es una variable que influye directamente en la producción, ya que para algunas direcciones se pueden tener efectos de estela entre los aerogeneradores y efectos de contracción de líneas de flujo en particular en sitios de topografía compleja [Amenedo \(2003\)](#).

La producción de energía eólica tiene una característica a lo largo del año. Para Uruguay en [Cornalino \(2015\)](#) se presentó el estudio del comportamiento del viento en las distintas regiones del país a lo largo de los períodos anuales y se mostró su variabilidad estacional. El ciclo diario en la capa límite atmosférica [Gutiérrez \(2018a\)](#), es de suma relevancia en la producción de energía eólica. Los períodos de estabilidad atmosférica se dan por la noche, y se caracterizan por un flujo de calor desde la atmósfera a la superficie [Stull \(1988\)](#). Luego durante el día la superficie terrestre absorbe la energía de la radiación solar y transmite calor a las capas más bajas de la atmósfera, provocando inestabilidad atmosférica durante el día. En [De Almeida \(2016\)](#) se analizó el ciclo diario en el perfil de velocidades en altura en una torre en la región de estudio.

En base a estas consideraciones se utilizan de las simulaciones del WRF-ARW, las variables físicas de la velocidad media horaria del viento, dirección media horaria del viento y la densidad media horaria del aire, siendo las mismas a aproximadamente 100 metros de la superficie (tomando esta altura como altura de referencia de los ejes de los aerogeneradores instalados). También se utilizaron en cuatro de los ocho modelos desarrollados en base a WRF-RNA y WRF-RL, las variables asociadas a las estacionalidad anual (declinación solar, Abal (2013)) y a la estabilidad atmosférica (variables difusas), Ross (2010).

Modelos WRF-RL

Considerando la ecuación 7.4, se plantea un modelo de regresión lineal en el que la potencia pronosticada (\hat{P}) depende de la densidad ($\hat{\rho}$) y la velocidad (\hat{v}) pronosticada a la altura del eje del aerogenerador por el modelo WRF, siendo a_p el coeficiente calculado por medio de una regresión lineal ($\hat{P} = a_p X$, con $X = \hat{\rho}\hat{v}^3$). Los coeficientes a_p se calculan durante el período de calibración (entrenamiento) para cada parque eólico. El modelo de RL es del tipo regresión lineal en X , incluye dos variables independientes involucradas en dicho modelo (velocidad del viento y densidad del aire) las cuales sirven como entrada para pronosticar la variable dependiente (potencia), Jobson (2018).

A su vez, el modelo WRF-RL CLUSTER se le realiza el análisis de sensibilidad en esquemas numéricos de la capa límite y en la corrección de la velocidad por análisis cluster. Las figuras 7.3, 7.4, 7.5 y 7.6 presentan esquemas con cuatro variaciones de configuraciones utilizadas para el desarrollo de esta tesis, en base al modelo WRF-RL.

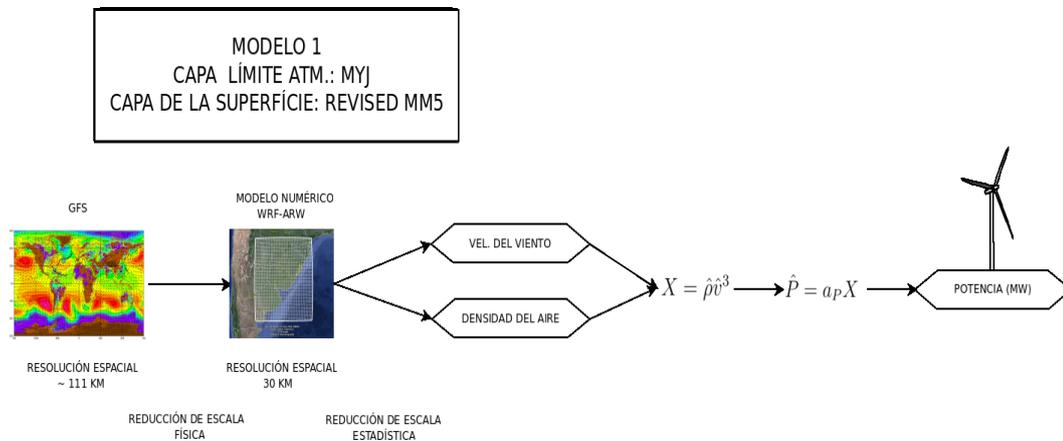


Figura 7.3: Esquema del modelo 1 de pronóstico. Fuente: Propio Autor

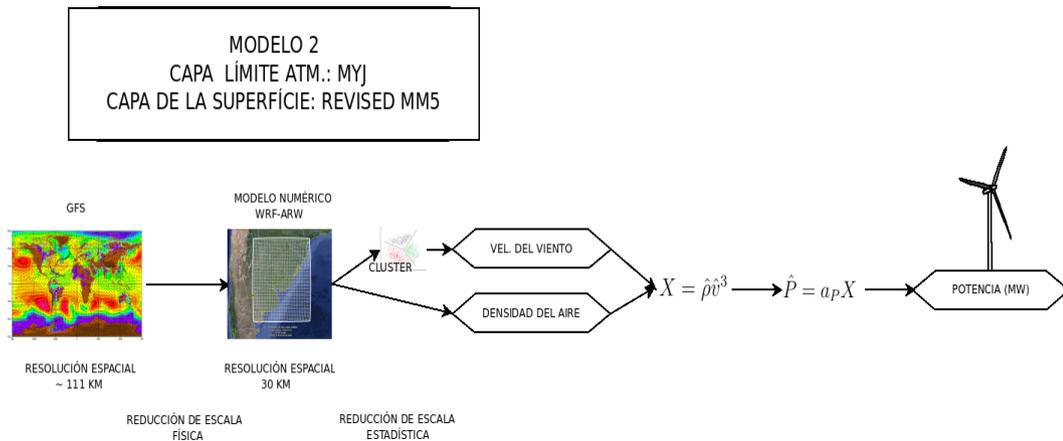


Figura 7.4: Esquema del modelo 2 de pronóstico. Fuente: Propio Autor

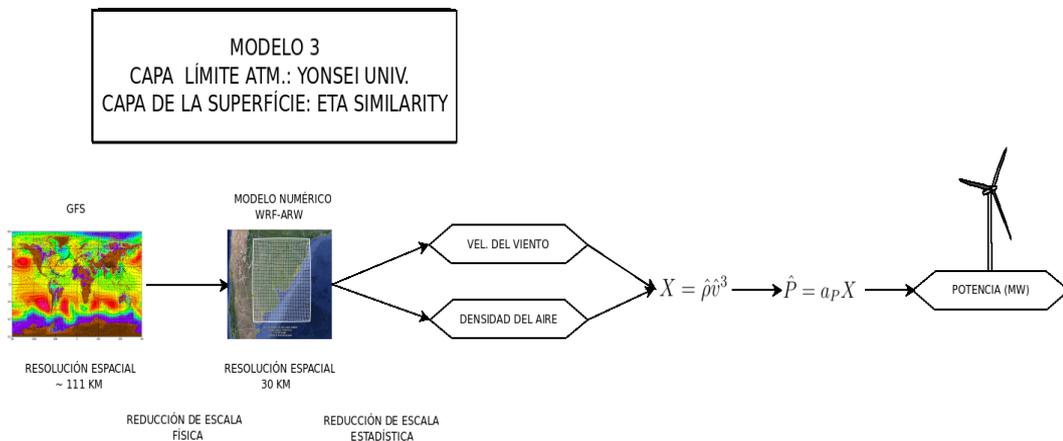


Figura 7.5: Esquema del modelo 3 de pronóstico. Fuente: Propio Autor

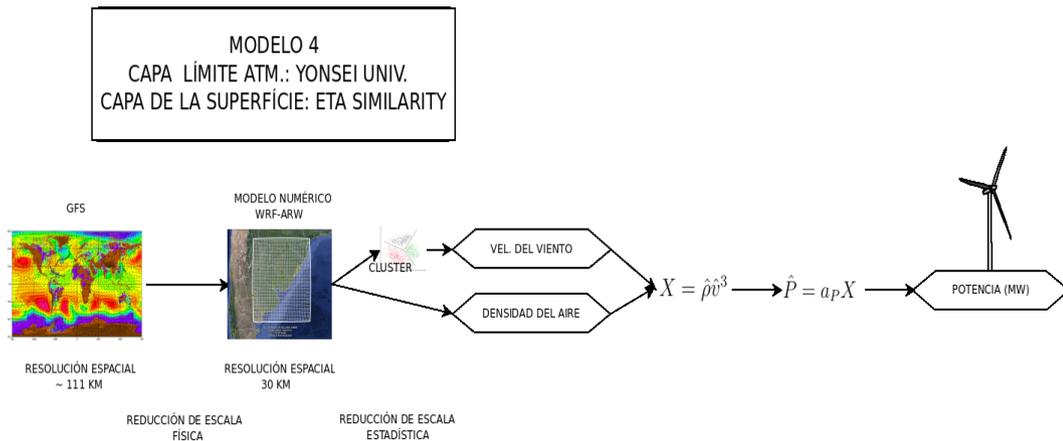


Figura 7.6: Esquema del modelo 4 de pronóstico. Fuente: Propio Autor.

Modelos WRF-RNA

El modelo WRF-RNA, toma como variables de entrada la densidad del aire ($\hat{\rho}$), la velocidad del viento (\hat{v}) y la dirección del viento pronosticada a la

altura del eje del aerogenerador por el modelo WRF-ARW. Además se agrega la declinación solar de modo de incorporar la estacionalidad anual como información de entrada y las variables difusas [Ross \(2010\)](#) asociadas a la estabilidad atmosférica. La declinación solar es el ángulo formado por la línea Tierra-Sol con el plano ecuatorial de la Tierra [Spencer \(1971\)](#). Por convención, se toma positivo cuando la línea Tierra-Sol está al Norte del plano ecuatorial, lo que corresponde al invierno del H.S, [Abal \(2013\)](#). La declinación es cero en los equinoccios y en estos puntos presenta su menor variación diaria (menor a 0.5 grados por día). El mayor y menor valor se dan en el solsticio de invierno y verano (23.45 y -23.45 grados respectivamente). Para los equinoccios de otoño y primavera, el valor angular de la declinación solar es cero. Se definen las variables [0 a 1] con una variación diaria (lógica difusa fuzzy) para la discriminación de la estabilidad e inestabilidad atmosférica, los cuales están asociados a los períodos nocturnos y diurnos respectivamente. La figura 7.7 presenta la caracterización de la declinación solar lo largo del año para el hemisferio sur (izquierda) y la discriminación día/noche por variable fuzzy (derecha).

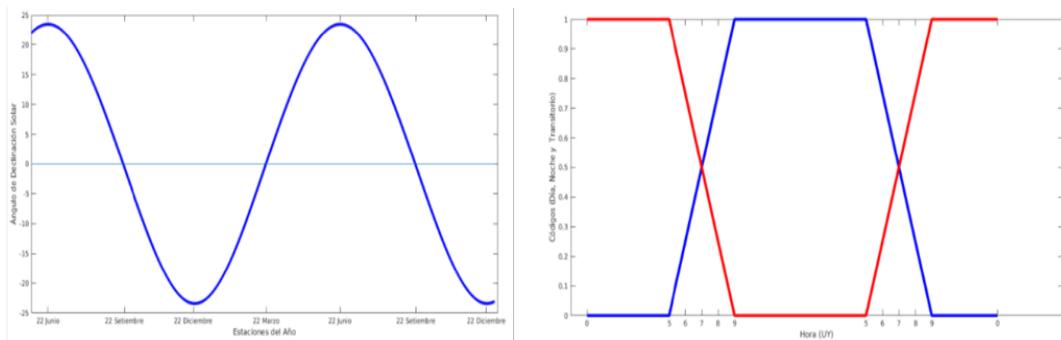


Figura 7.7: Declinación solar y discriminación atmosférica. Fuente: Propio Autor.

Los códigos para la discriminación atmosférica fueron implementados en dos columnas, donde una representó el día y otra la noche. Entre las 5 horas y las 9 horas de la mañana los códigos fueron intermedios entre 0 y 1, representando el periodo transitorio.

Las variables declinación solar y discriminación atmosférica buscaron caracterizar informaciones importantes para la red, referentes al comportamiento distinto de la producción de energía eólica en ambos casos.

En base a un aprendizaje supervisado se utilizó el método retropropagación, [Rumelhart \(1986b\)](#) para el entrenamiento de la red neuronal, donde las variables de entrada del modelo fueron introducidas junto a los datos de po-

tencia para el proceso de aprendizaje, se consideraron datos de potencia media horaria, (variable de pronostico denominada blanco) para cada parque eólico. Fueron utilizadas dos capas en la red neuronal (una capa oculta y una de salida), donde la capa oculta tuvo 10 neuronas y la capa de salida 1 neurona. Esta definición del número óptimo de neuronas se hizo mediante tests para parques individuales, analizando el desempeño del modelo mediante el cambio del número de neuronas.

El método utilizado para la normalización de los datos de entrada de la red neuronal fue “mapstd” (normalización por desviación estándar), lo cual normaliza los datos entre 0 y 1. De los datos de entrenamiento se utilizó 70 % para el entrenamiento, 15 % para la validación y 15 % para test. La función de entrenamiento utilizada fue Levenberg-Marquardt backpropagation (trainlm), Marquardt (1963), Hagan (1994) la función de aprendizaje fue Gradient descent with momentum weight and bias learning function (learngdm), Beale (2018) . La función de performance fue el error medio cuadrático (mse). Las funciones de transferencia/activación utilizadas para la capa intermedia fue Hyperbolic tangent sigmoid (tansig) y lineal en la capa de salida (purelin), Beale (2018).

La figura 7.8 presenta un diagrama que muestra la configuración utilizada en el modelo WRF-RNA.

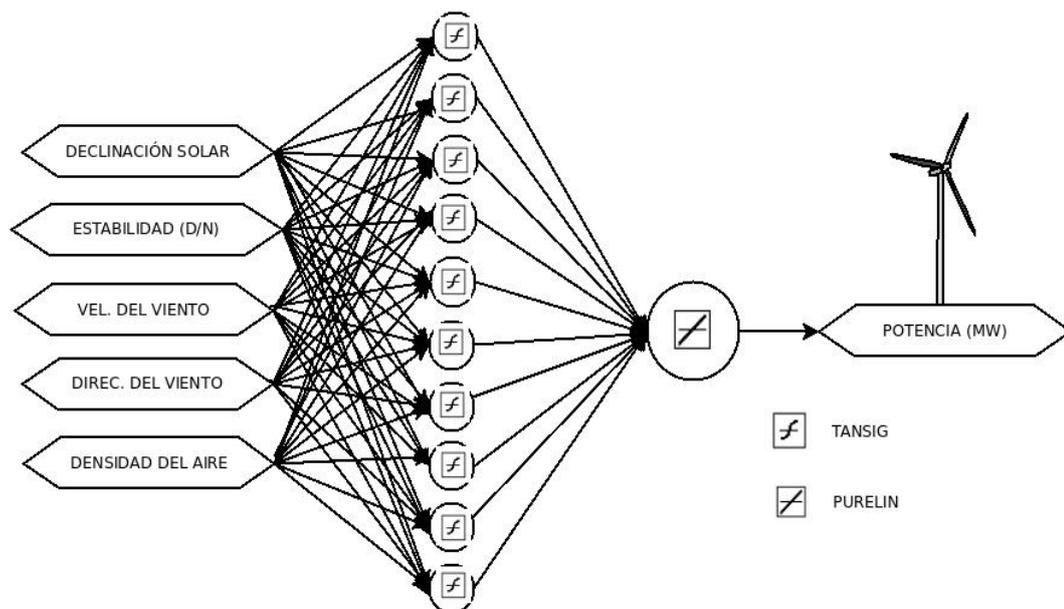


Figura 7.8: Configuración de la herramienta con uso de los modelos WRF-ARW y de RNA.

Las figuras 7.9, 7.10, 7.11 y 7.12 presentan esquemas con cuatro variaciones de configuraciones utilizadas para el desarrollo de esta tesis, en base al modelos WRF-RNA.

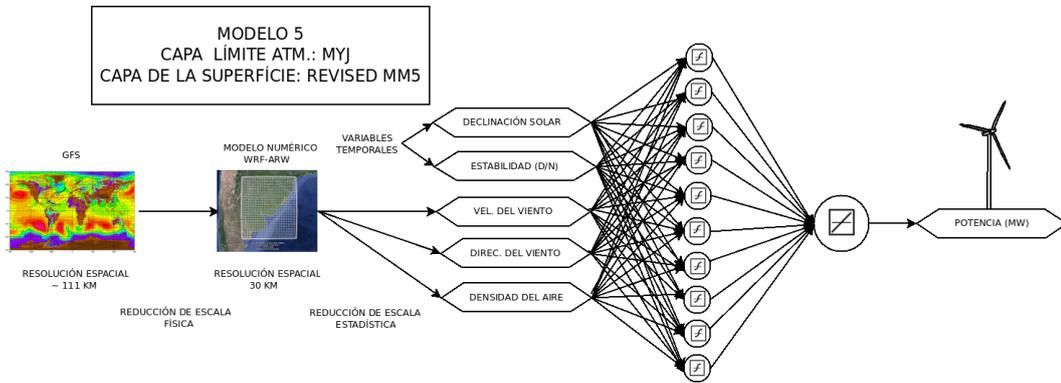


Figura 7.9: Modelo 5 en base a WRF-RNA. Fuente: Propio Autor.

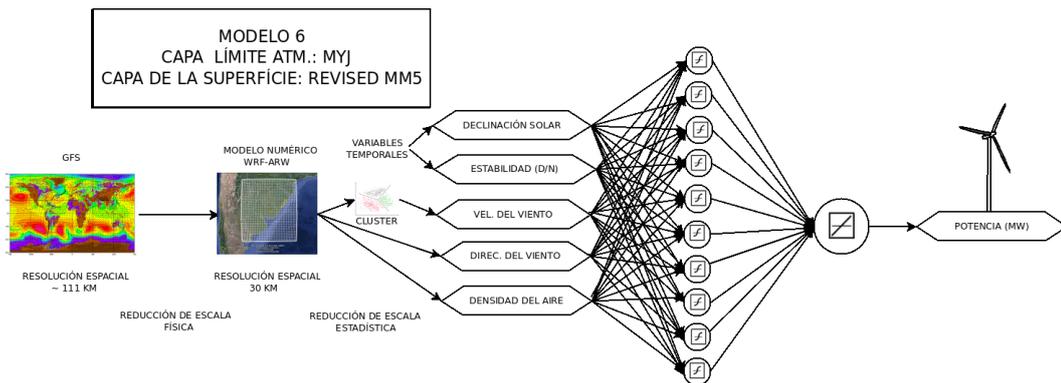


Figura 7.10: Modelo 6 en base a WRF-RNA. Fuente: Propio Autor.

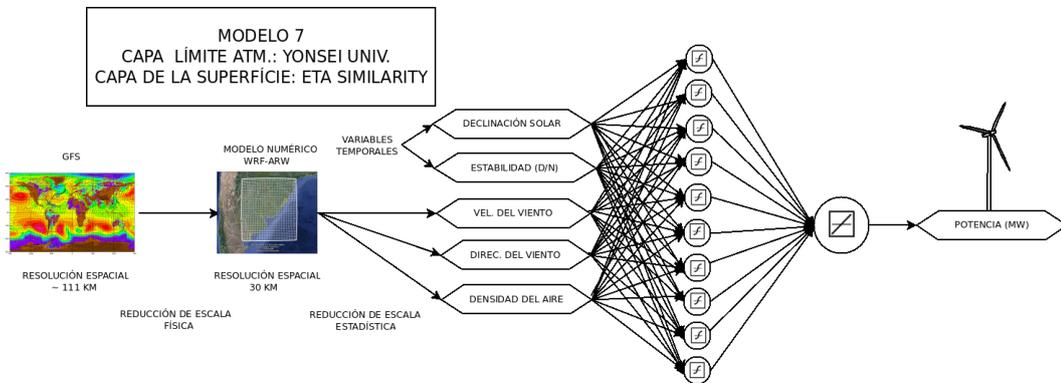


Figura 7.11: Modelo 7 en base a WRF-RNA. Fuente: Propio Autor.

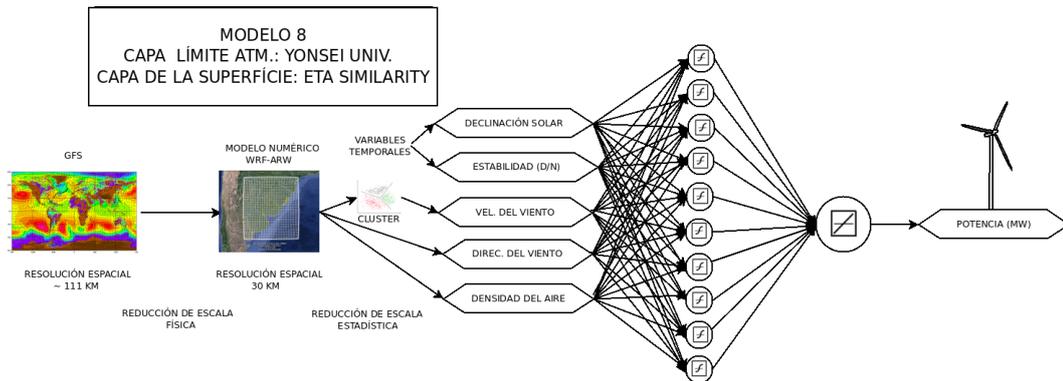


Figura 7.12: Modelo 8 en base a WRF-RNA. Fuente: Propio Autor.

La metodología de utilizar modelos de pronóstico con distintas configuraciones, busca comparar e identificar las fortalezas y los puntos débiles de cada modelo desarrollado. Con la comparación de la calidad de cada pronóstico, el objetivo es identificar el mejor método y reproducirlo para los pronósticos operativos de energía eólica en Uruguay, teniendo como base el conocimiento adquirido en este trabajo.

Capítulo 8

Resultados

En esta sección se presentan los resultados de los ocho modelos descritos en el capítulo anterior, se hacen comparaciones entre ellos y se profundiza el análisis en el modelo con mejor desempeño. Los resultados de cada modelo se presentan en forma detallada, en los apéndices de la tesis, donde se puede consultar los indicadores de análisis cluster, métricas de desempeño, como el error medio absoluto y correlación lineal, para todo el conjunto de parques eólicos, con distintas cantidades de datos para el período de entrenamiento.

La evaluación del promedio del error medio absoluto de los ocho distintos modelos de pronóstico desarrollados, es presentado en la figuras 8.1.

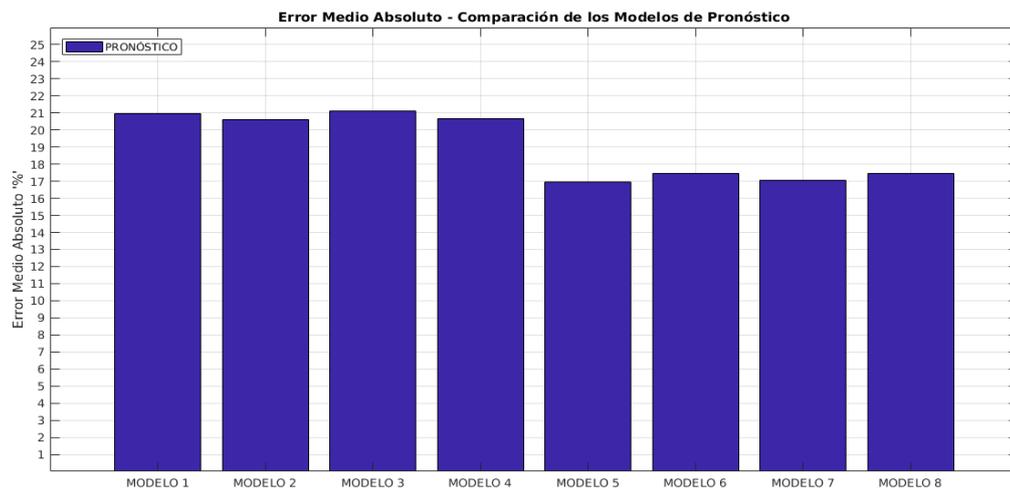


Figura 8.1: Evaluación del promedio del error medio absoluto de los ocho modelo de pronóstico desarrollados. Fuente: Propio Autor.

El promedio de la correlación lineal de cada uno de los modelos de pronósticos desarrollados, es presentado en la figura 8.2.

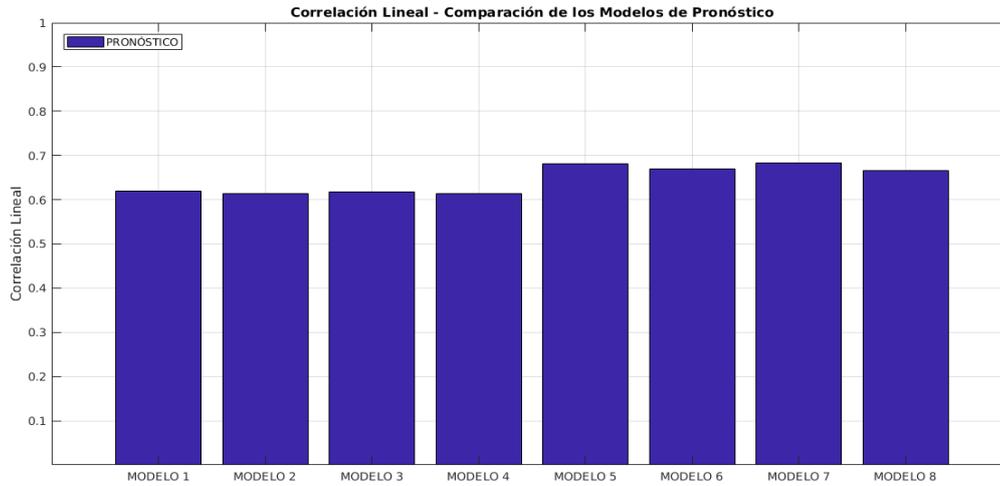


Figura 8.2: Evaluación del promedio de la correlación lineal de cada uno de los ocho modelo de pronóstico desarrollados. Fuente: Propio Autor.

Los mejores resultados son de los modelos 5 al 8, cuando comparados a los modelos 1 al 4, de acuerdo a las figuras 8.1 y 8.2. Los modelos de mejor performance tienen incorporado el uso de RNA's, las cuales tienen una mejor capacidad de pronosticar problemas no lineales. La figura 8.3, presenta el promedio del error medio absoluto (%) del modelo 5 (mejor performance), para el período de entrenamiento y pronóstico de la RNA, divididos en tres conjuntos de parques eólicos, según la cantidad de datos para el entrenamiento.

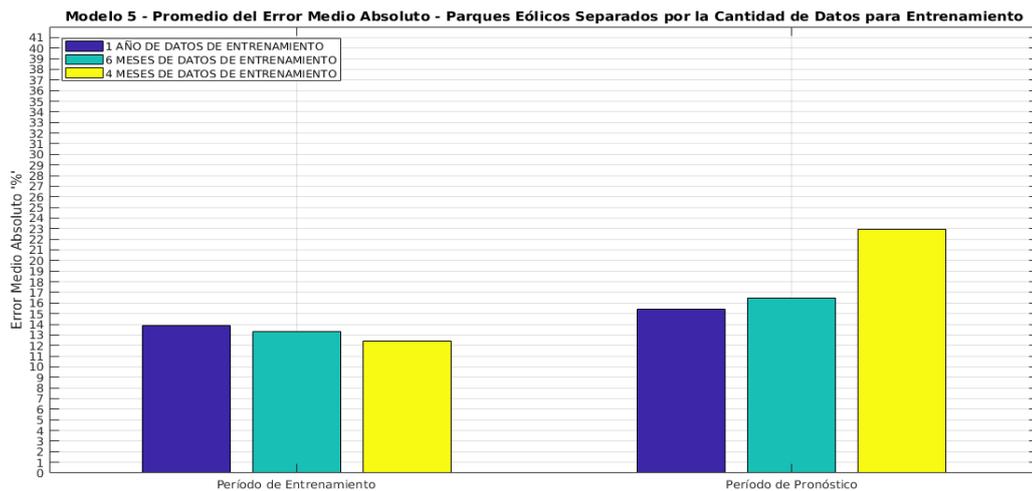


Figura 8.3: Promedio del Error medio absoluto (%) para el período de entrenamiento y período de pronóstico, para el modelo de pronóstico 5. Fuente: Propio Autor.

Buscando verificar el promedio del error medio absoluto cada parque eólico

de modo individual, se presenta en la figura 8.4, el mejor resultado del modelo 5 en el período de entrenamiento de la red neuronal artificial, así como sus pronósticos para cada uno de los parques eólicos estudiados.

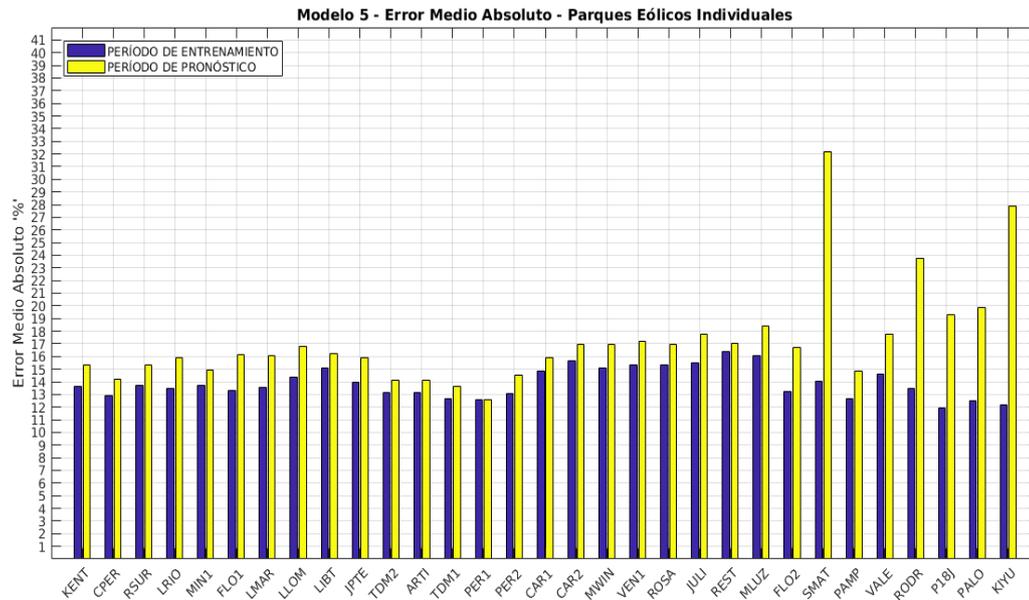


Figura 8.4: Promedio del Error medio absoluto (%), para el modelo 5 de pronóstico, con los errores asociados al período de entrenamiento y pronóstico de la RNA, para todo el conjunto de 31 parques eólicos presentados en el trabajo. Fuente: Propio Autor.

En la figura 8.4, los últimos siete parques eólicos (de la izquierda a la derecha), que son SMAT, PAMP, VALE, RODR, P18J, PALO y KIYÚ, son los que tuvieron datos de entrenamiento con período igual o inferiores a 6 meses. Se verifica en la figura 8.4, que dichos parques eólicos son los que tuvieron una mayor diferencia del error medio absoluto entre el entrenamiento y el pronóstico.

Buscando verificar la importancia del período de entrenamiento para una RNA, se presenta en la figura 8.5, una comparación del promedio del error medio absoluto (%) y promedio de correlación lineal, para el pronóstico del modelo 5, en dos versiones: en una primer versión se utiliza el 100% de los datos disponibles para el período de entrenamiento de la red neuronal (barras a la izquierda) y en una segunda versión se utiliza el 50% de los datos de entrenamiento disponibles (barras a la derecha), siendo así en esta versión que el conjunto de parques eólicos tuvieron 6 meses, 3 meses y 2 meses de datos para el entrenamiento.

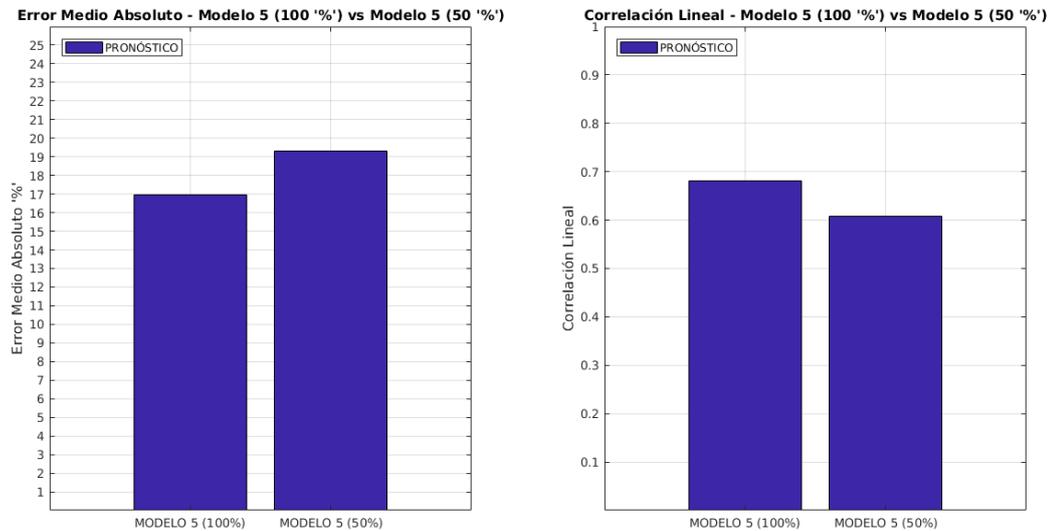


Figura 8.5: Promedio del Error medio absoluto (%) (izquierda) y promedio de correlación lineal (derecha), para el modelo 5, con la comparación entre un modelo con que utiliza el 100% de los datos disponibles para el período de entrenamiento (izquierda) y otro que utiliza el 50% de los datos de entrenamiento (derecha). Fuente: Propio Autor.

En base a la figura 8.3, 8.4 y 8.5 se evidencia que cuanto mayor sea la cantidad de datos para entrenar la red, mejores son los resultados de pronóstico generados. La figura 8.6, presenta la comparación del promedio del error medio absoluto (%) del modelo 5, para el caso de la figura 8.5, para todos los parques eólicos.

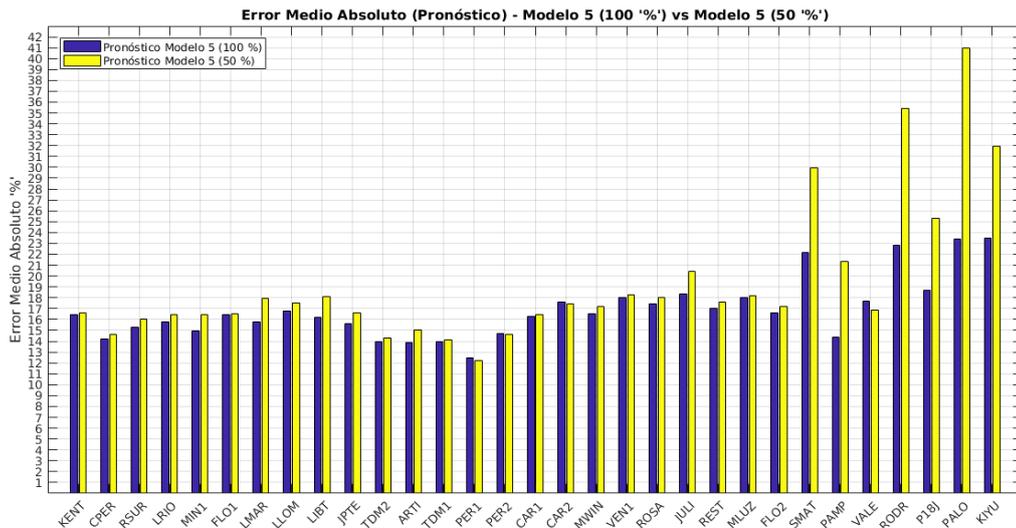


Figura 8.6: Modelo 5 en base a WRF-RNA. Fuente: Propio Autor.

Por fin, se presentan en la figura 8.7, los valores de MAE (superior) y

BIAS (inferior) para el ciclo diario, en base al pronóstico realizado para todo el período de evaluación con dos parametrizaciones de capa límite atmosférica y con/sin análisis cluster. En base al BIAS de corrección, a cada una de las agrupaciones del análisis cluster fueron aplicados a los parques cercanos el mismo tipo de corrección de BIAS con los valores correspondientes a la corrección de cada torre cercana al parque eólico.

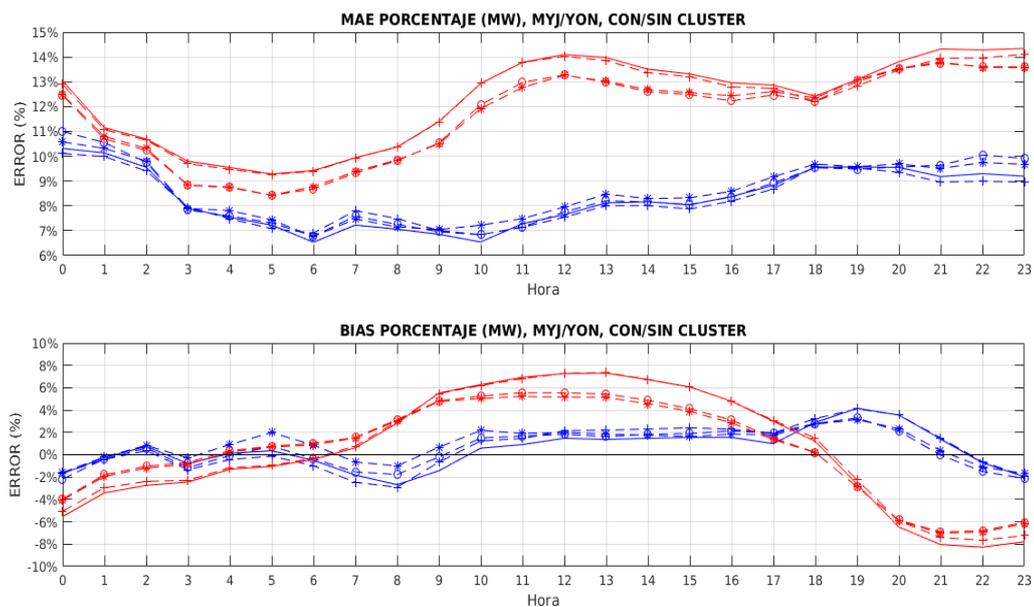


Figura 8.7: Desempeño de los modelos de pronóstico en base a BIAS y MAE, con modelos WRF-RNA (azul) y WRF-RL (rojo). Los modelos con cluster son representados por “-o” (MYJ) y “-*” (Yonsei) y sin cluster con “-” y “- continua”. Fuente: Propio Autor.

Entre los dos modelos desarrollados se detecta que las parametrizaciones físicas de capa límite atmosférica no cambian significativamente los resultados en cada uno de los modelos utilizados. En cuanto al análisis cluster utilizado se detecta una mejora para el modelo en base a regresiones lineales. Para el modelo de redes neuronales artificiales la utilización previa de análisis cluster en los datos de velocidad media horaria del viento no tuvo un aporte para mejorar las métricas del modelo de pronóstico desarrollado.

Cuando son comparados los dos modelos desarrollados, de regresiones lineales y redes neuronales artificiales, se percibe una mejor performance del modelo de RNA para todas las configuraciones utilizadas, tanto parametrizaciones físicas de capa límite atmosférica del modelo WRF-ARW como para el uso o no de agrupaciones por cluster.

Capítulo 9

Conclusiones

En este trabajo se analizaron ocho modelos de pronósticos de energía eólica para un horizonte temporal de 24 horas, en base a corridas de baja resolución (30km) del modelo numérico de mesoescala WRF-ARW. Los modelos de pronósticos desarrollados se diferencian la utilización de dos distintas parametrizaciones físicas de capa límite atmosférica del WRF-ARW (Mellor-Yamada-Janjic y Yonsei University), corrección de datos de velocidad del viento por análisis cluster (via mediciones de velocidad media del viento de torres cercanas a los parques eólicos estudiados) y no utilización de este método, así como postprocesamiento basado en los métodos de regresiones lineales (RL) y redes neuronales artificiales (RNA).

Los resultados fueron evaluados para un total de 31 parques eólicos ubicados en Uruguay, los cuales sumados, tienen una potencia nominal instalada 1267.4 MW, lo que representa el 85.25% de toda la potencia nominal de energía eólica instalada en Uruguay hasta el presente.

Entre los dos modelos de pronósticos desarrollados, se detecta que el método de postprocesamiento utilizado fue el factor más relevante para definir los mejores pronósticos. Los modelos en base a un postprocesamiento con redes neuronales artificiales tuvieron un mejor resultado, cuando comparados a todos los modelos de pronósticos en base a un postprocesamiento con regresiones lineales, siendo independientes de la utilización o no de agrupaciones por cluster, así como por la parametrización de capa límite atmosférica utilizada en el modelo WRF-ARW.

La corrección de velocidad media del viento por análisis cluster, tuvo un aporte cuanto a mejoras en pronosticar la energía eólica para los modelos

basados en un postprocesamiento con regresiones lineales. Para los modelos de pronóstico basados en un postprocesamiento con uso de RNA's, el método de análisis cluster tuvo resultados inferiores comparado a los modelos que no utilizaron datos de velocidad del viento corregidos por análisis cluster.

Las parametrizaciones físicas de capa límite atmosférica utilizadas en el modelo WRF-ARW, se verifica en base a los resultados presentados, que para todos los modelos presentados, tanto los que utilizaron Mellor-Yamada-Janjic, cuanto los que utilizaron Yonsei University, mantuvieron resultados equivalentes, siendo portanto las parametrizaciones físicas un factor que no tuvo influencia significativa para la determinación en la mejora o no de un modelo de pronóstico.

Entre todos los modelos presentados, el modelo 5 fue el que tuvo el mejor resultado, siendo dicho modelo una configuración de corridas del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic, datos de velocidad media del viento provenientes del modelo WRF-ARW sin corrección por agrupaciones de cluster y postprocesamiento en base a RNA's. Analizando los resultados detallados para el modelo 5, se verificó la importancia de tener una cantidad de datos mínima de entrenamiento que sea representativa del comportamiento del viento a lo largo de un período anual, siendo significativamente distinta la performance del modelo para parques eólicos con período de entrenamiento de doce meses, 6 meses y 4 meses. Cuando fueron presentados periodos de datos de entrenamiento de seis y cuatro meses a las RNA's, se verificó una significativa diferencia entre los errores de entrenamiento y los errores de pronóstico. Para estas cantidades de datos de entrenamiento, la RNA no fue capaz de presentar patrones de velocidad media horaria del viento, densidad media horaria del aire y dirección media horaria del viento relacionadas a potencias medias horarias de los parques eólicos, que fuera capaz de establecer un aprendizaje frente a nuevos datos de variables físicas presentadas para el pronóstico de la energía eólica.

Se concluye en este trabajo, que la utilización de un modelo numérico de mesoescala, con base física de los procesos de la atmósfera, combinado con un método de postprocesamiento en base a redes neuronales artificiales, logra caracterizar de mejor forma los ciclos del viento en la capa límite atmosférica, más específicamente en la altura de interés para la generación de energía eléctrica a partir de parques eólicos. Las RNA's tienen potencializadas sus habilidades de postprocesamiento, en pronosticar la energía eólica, cuando se dispone de un

período de datos de entrenamiento que represente todo un período de variación de las distintas estaciones del año (otoño, invierno, primavera y verano). Además, con esta cantidad de datos de entrenamiento, se puede utilizar el error del entrenamiento de la RNA como referencia para el error a ser presentado por el pronóstico, dando así un buen margen de incertidumbre cuanto al pronóstico solamente con el análisis previo del resultado del entrenamiento de la RNA.

La técnica de un modelo en base al modelo numérico WRF-ARW y RNA presenta una oportunidad para desarrollar mejoras en los pronósticos operativos de energía eólica. Buscar variaciones en los datos de entrada del modelo WRF-ARW, como el uso de ensembles (pronósticos por conjuntos) con perturbaciones en las condiciones iniciales, así como agregar una mayor cantidad de datos de entrenamiento a las RNA's, como datos históricos, así como velocidades de viento pronosticadas en parques eólicos cercanos, son opciones válidas, buscando así el desarrollo de modelos, de modo a disminuir la incertidumbre en pronósticos de corto plazo de energía eólica, aportando así informaciones imprescindibles para el despacho y la planificación en el sistema eléctrico.

Al fin, se concluye que las principales contribuciones de este trabajo fueron:

- Identificar las redes neuronales artificiales como una buena herramienta para utilización en los pronósticos de energía eólica, junto al modelo WRF-ARW.
- Identificar la importancia de entrenar las RNA's con un período de datos de entrenamiento adecuado, de modo que se logre tener en el período de aprendizaje, datos en distintas estaciones del año.
- Lograr una metodología para que sea implementada una nueva versión de pronóstico operativo UTE-FING-IMFIA, para los parques eólicos en Uruguay.

Referencias bibliográficas

61400-1, I. (2005). Wind turbines - part 1: Design requirements. International Electrotechnical Commission TM X-72835.

Abal, G., D. V. (2013). Manual técnico de energía solar térmica, volumen i: Fundamentos. Publicación Electrónica TM X-72835.

ABEEólica (2019). Associação brasileira de energia eólica, eólica já é a segunda fonte da matriz elétrica brasileira com 15 gw de capacidade instalada @BOOKLET.

Ackermann, T. (2005). *Wind Power in Power Systems*. John Wiley e Sons, Stockholm, Sweden.

ADME (2015). Procedimiento para restricciones operativas aplicable a generadores de fuente eólica y solar del sistema interconectado nacional (sin @BOOKLET.

ADME (2018). Informe anual 2017. Administración del Mercado Eléctrico (ADME) TM X-72835.

Agency, D. E. (2012). Energy police in denmark. Energy Police in Denmark 1.

Alonso, R. (2017). *Estimación del Recurso Solar en Uruguay Mediante Imágenes Satelitales*. Tesis de doctorado, Universidad de la República, UdelaR, Montevideo, Uruguay.

Amenedo, J.L.R., B. J. G. S. (2003). *Sistemas Eólicos de Producción de Energía Eléctrica*. Editorial Rueda SL, Madrid.

Beale, M.H., H. M. D. H. (2018). Neural network toolbox matlab user's guide. Neural Network Toolbox MATLAB User's Guide TM X-72835.

- Bowdwn, G.J., B. P. S. V. T. J. (1983). The weibull distribution function and wind power statistics. *Wind Engineering*, 7(2):85–98.
- Braga, A. de P., C. A. P. d. L. L.-T. (2000). *Redes Neurais Artificiais: Teoria e Aplicações*. LTC Editora, Rio de Janeiro.
- Bream, A. L. (2017). Deep learning 101 - part 1: History and background, @BOOKLET.
- Castillo, C.G., T. A. G. O. (2015). A review on the recent history of wind power ramp forecasting. *Renewable and Sustainable Energy Reviews*, 52(6):1148–1157.
- Chen, S.A., S. W. (2002). A one-dimensional time dependent cloud model. *Journal of the Meteorological Society of Japan*, 80(1):99–118.
- Chen, S.A., S. W. (2004). The kain–fritsch convective parameterization: An update. *Journal of Applied Meteorology*, 43(1):170–181.
- Clifford, K. (2011). Wrf-model performance for wind power forecasting in the coast ranges of central california. Master dissertation, San Jose State University, San Jose, California, USA.
- Cornalino, E. (2015). Descripción del comportamiento del recurso eólico nacional para su modelado dentro del sin. Ms. disertación, Universidad de la República, Montevideo, Uruguay.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(1):273–297.
- Custódio, R. (2013). *Energia Eólica para Produção de Energia Elétrica*. Synergia Editora, Rio de Janeiro, Brasil.
- Darrieus, G. J. M. (1931). Turbine having its rotating shaft transverse to the flow of the current. United States Patent Office Vol. 1, No. 2, pp. 1-3.
- De Almeida, E., G. A. R. M. C. G. C.-J. (2016). Descrição estatística do ciclo diário do vento nos primeiros 100 metros de altura da c.l.p. na localidade de colonia eulacio, uruguai. *Ciência e Natura*, 38(1):426–434.

- De Jong, P., D. R. S. J. U. S. K.-A. T. E. (2017). Forecasting high proportions of wind energy supplying the brazilian northeast electricity grid. *Applied Energy*, 195(6):538–555.
- De Mello, S., C. G. G. A. (2015). Operational wind energy forecast with power assimilation. In *14Th International Conference on Wind Engineering*, pages 2435–2438, Porto Alegre, Brazil.
- Dudhia, J. (1989). Numerical study of convection observed during the winter monsoon experiment using a mesoscale two dimensional model. *Journal of the Atmospheric Sciences*, 46(20):3077–3107.
- Dumitri, C.D., G. A. (2017). Daily average wind energy forecasting using artificial neural networks. *Procedia Engineering*, 181(3):829–836.
- Filho, R. T. A. (2016). Aplicação de redes neurais no controle de tuberculose bovina. Tese de mestrado, Universidade Federal do Rio Janeiro, UFRJ, Rio de Janeiro, Brasil.
- Fox, D. (1981). Judging air quality model performance. *Bulletin of the American Meteorological Society*, 62(1):599–609.
- Fujita, T. (1981). Tornadoes and downbursts in the context of generalized planetary scales. *Journal of the Atmospheric Sciences*, 38(8):1511–1534.
- Gash, R., T. J. (2012). *Wind Power Plants. Fundamentals, Design, Construction and Operation. Second Edition*. Springer, Berlin.
- Georgilakis, P. (2008). Technical challenges associated with the integration of wind power into power systems. *Renewable and Sustainable Energy Reviews*, 12(1):852–863.
- Goodfellow, I.J., P.-A. J. M. M. X. B. W.-F. D. O. S.-C. A. B. Y. (2014). Generative adversarial nets. Department d’informatique et de recherche opérationnelle, University of Montreal, Canada 1.
- Gutiérrez, A. (2011). Herramientas de predicción de muy corta y corta duración de la energía eólica. Tesis de posgrado, Universidad de la República, Montevideo, Uruguay.

- Gutiérrez, A., A.-E. P. C. R. M. O. S.-C. G. B. A.-M. D. C. J. (2018a). Pronósticos operativos de energía eólica para la gestión de los sistemas eléctricos en la región. *Revista de Energía Latinoamérica y el Caribe*, 2(1):1–10.
- Gutiérrez, A., C.-J. C. G. D. M. S. (2015). Forecast of cut out events in emanuelle cambilargiu 20 mw wind farm. In *14Th International Conference on Wind Engineering*, pages 2435–2438, Porto Alegre, Brazil.
- Gutiérrez, J.M., C.-R. C. A. S. C. (2004). *Redes Probabilísticas y Neuronales en las Ciencias Atmosféricas*. Ministerio de Medio Ambiente de España, Madrid.
- Gutiérrez, A., F.-R. (2018b). A new gust parameterization for weather prediction models. *Journal of Wind Engineering e Industrial Aerodynamics*, 117(1):45–59.
- Gutiérrez, A., F.-R. (2018c). A new gust parameterization for weather prediction models. *Journal of Wind Engineering e Industrial Aerodynamics*, 177(1):45–49.
- GWEC (2019). 51.3 gw of global wind capacity installed in 2018, @BOOKLET.
- GWEC, G. W. E. C. (2018). Global wind report, annual market update. Global Wind Report, Annual Market Update TM X-72835.
- Hagan, M.T., M. M. (1994). Training feed-forward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6):989–993.
- Haykin, S. (2009). *Neural Networks and Learning Machines, Third Edition*. Pearson, Hamilton, Ontario, Canada.
- Hebb, D. (1949). *The Organizarion of Bheavior*. John Wiley and Sons, New York.
- Hinton, G. and Salakhutdinov, R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(1):273–297.
- Hong, S.Y., N. Y. D. J. (2006). A new vertical diffusion package with an explicit treatment of entrainment processes. *Monthly Weather Review*, 134(1):2318–2341.

- Hopfield, J. (1982). Neural networks and physical systems with emergent collective properties. *Proc. Natl. Acad. Sci. USA*, 79(1):2554–2558.
- Hoven, I. (1956). Power spectrum of horizontal wind speed in the frequency range from 0.0007 to 900 cycles per hour. *Journal of Meteorology*, 14(1):160–164.
- IPCC (2019). Intergovernmental panel on climate change, @BOOKLET.
- IRENA, I. R. E. A. (2017). Renewable power generation costs in 2017. Renewable Power Generation Costs in 2017 TM X-72835.
- Issawi, C. (1978). The 1973 oil crisis and after. *Journal of Post Keynesian Economics* Vol. 1, No. 2, pp. 3-26.
- Janjic, Z. (2014). The step mountain eta coordinate model: Further developments of the convection, viscous sublayer, and turbulence closure schemes. *Monthly Weather Review*, 122(1):927–945.
- Jobson, J. (2018). *Multiple Linear Regression. In: Applied Multivariate Data Analysis*. Springer, New York.
- Kaimal, J.J., F. J. (1994). *Atmospheric Boundary Layer Flows, Their Structure and Measurement*. Oxford University Press, New York.
- Kalnay, E. (2003). *Atmospheric Modeling, Sata Assimilation and Predictability*. Cambridge University Press, Cambridge.
- Lange, M., F. U. (2005). *Physical Approach to Short-Term Wind Power Prediction*. Springer, Oldenburg, Germany.
- LES (2017). Mapa solar del uruguay, segunda version @BOOKLET.
- Lin, C. Y. (1984). Global pattern of energy consumption before and after the 1974 oil crisis. *Economic Development and Cultural Change* Vol. 32, No. 4, pp. 781-802.
- Lucas, E.A., G. A. M. M. B. G. (2016). Simulações do perfil vertical do vento na camada limite atmosférica planetária com o modelo wrf-arw. In *MCSUL - Conferência Sul em Modelagem Computacional*, pages 448–457, Rio Grande, Brasil.

- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Symposium on Math, Statistics, and Probability*, pages 281–297, Berkeley, California.
- MacroTrends (2018). Crude oil prices - 70 year historical chart, @BOOKLET.
- Markowski, P., R. Y. (2010). *Mesoscale Meteorology in Midlatitudes*. Wiley-Blackwell, Pensilvania.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. *SIAM Journal on Applied Mathematics*, 11(2):431–441.
- McCulloch, W. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5(1):115–133.
- Mendel, M. and McLaren, R. (1970). *Adaptative, Learning and Pattern Recognition systems: Theory and Applications*. Academic Press, New York.
- Meted (2007). Funcionamiento de los modelos de mesoescala, @BOOKLET.
- Meted (2010). Fundamentos de los modelos: Versión 2, @BOOKLET.
- Meted (2014). Fundamentos de pnt: Física del modelo, @BOOKLET.
- MIEM (2009). Mapa eólico de uruguay, @BOOKLET.
- MIEM (2019). Energía solar en uruguay, @BOOKLET.
- MIEM-DNE (2008). Política energética 2005-2030. Ministério de Indústria, Energía y Minería (MIEM), Dirección Nacional de Energía (DNE) TM X-72835.
- Minsky, M. and Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Massachusetts.
- Mlawer, E.J., S. J. P. D. M. J. C. S. (1997). Radiative transfer for inhomogeneous atmospheres: Rrtm, a validated correlated-k model for the longwave. *Journal of the Geophysical Sciences*, 102(14):663–682.
- Moraes, M. (2004). Ferramenta para a previsao do vento e dispersao de poluentes na micro-escala atmosférica. Tese de doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil.

- NCAR (2018). National center for atmospheric research, @BOOKLET.
- NCAR (2019). Weather research and forecasting model arw version 4 modeling system user's guide. NCAR Technical Note 1.
- NCEP (2018). National centers for environmental prediction, @BOOKLET.
- Neha Yadav, Anupam Yadav, M. K. (2015). *An Introduction to Neural Network Methods of Differential Equations*. Springer, Warsaw.
- Noah (2014). Implementation and verification of the unified noah land surface model in the wrf model. Implementation and Verification of the Unified Noah Land Surface Model in the WRF Model TM X-72835.
- ONS (2018). A implantação do dessem na programação diária da operação e para a formação do preço horário - pldh, @BOOKLET.
- ONU (1972). Report of the united nations conference on the human environment. Report of the United Nations Conference on the Human Environment TM X-72835.
- ONU (1987). Our common future. Report of the World Commission on Environment and Development TM X-72835.
- ONU (1992). The rio declaration on environment and development. The Rio Declaration on Environment and Development TM X-72835.
- ONU (1998). Kyoto protocol to the united nations framework convention on climate change. Kyoto Protocol to the United Nations Framework Convention on Climate Change TM X-72835.
- ONU (2015). Acuerdo de paris. Acuerdo de París TM X-72835.
- ONU (2018). Naciones unidas, @BOOKLET.
- OPEP (2018). Organization of the petroleum exporting countries, @BOOKLET.
- Orlanski, I. (1975). The rational subdivision of scales for atmospheric processes. *Bulletin American Meteorological Society*, 56(13):527–530.
- Ozgonenel, O., D. W. (2017). Short-term wind speed estimation based on weather data. *Turk J Elec Eng e Comp Sci*, 20(3):829–836.

- Pielke, R. (2013). *Mesoscale Meteorological Modeling Academic Press*. International Geophysics Series, Colorado, United States.
- Porrini, C., G. A. (2018). Evaluación de esquemas numéricos de capa límite atmosférica en el modelo de mesoescala wrf. In *II Congreso Latino Americano de Engenharia do Vento*, pages 2435–2438, São Paulo, Brasil.
- RenovAR (2015). Programa de abastecimiento de energía eléctrica a partir de fuentes renovables, @BOOKLET.
- Rosas, P. A. C. (2004). *Dynamic Influences of Wind Power on The Power System*. Phd thesis, Technical University of Denmark, Kongens Lyngby, Denmark.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6):386–408.
- Ross, T. (2010). *Fuzzy Logic with Engineering Applications*. Wiley, New York.
- Rumelhart, D.E., H. G. W. R. (1986a). *Learning Internal Representations by Error Propagation*. MIT Press, Cambridge.
- Rumelhart, E., H. G. W. R. (1986b). Learning representations by back-propagating errors. *Nature*, 323(1):533–536.
- Rüdiger, M. (2014). The 1973 oil crisis and the designing of a danish energy policy. *Historical Social Research*, 39(4):94–112.
- Savonius, S. (1931). The s-rotor and its applications. *Mechanical Engineering*, 53(5):333–338.
- Skamarock, W.C., K. J. D. J. G. D. B. D.-D. M. H. X.-Y. W. W. P. J. (2008). A description of the advanced research wrf version 3. NCAR Technical Note 1.
- Soman, S. (2015). Description of wind turbines blades heights. In *14Th International Conference on Wind Engineering*, pages 2435–2438, Porto Alegre, Brazil.
- Soman, S.S., Z. H. M. O. M. P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. In *North American Power Symposium*, pages 1–10, Arlington, United States.

- Spencer, J. (1971). *Fourier Series Representations of the Position of the Sun*. Springer, New York.
- Stensurd (2012). An overview of convection parametrization, @BOOKLET.
- Stensurd, D. (2007). *Parameterizations Schemes Keys to Understanding Numerical Weather Prediction Models*. Cambridge University Press, Cambridge.
- Stull, R. (1988). *An Introduction to Boundary Layer Meteorology*. Kluwer Academic Publishers, Vancouver, Canada.
- Stull, R. (2016). Wrf hub-height wind forecast sensitivity to pbl scheme, grid length, and initial condition choice in complex terrain. *American Meteorological Society*, 32(1):493–509.
- UTE (2017). Sistema interconectado uruguayo, @BOOKLET.
- UTE (2019). Consulta geográfica de fuentes de generación, @BOOKLET.
- UTE-DPE (2013). Despachar energía eléctrica. UTE-DPE TM X-72835.
- Varanasi, J., T. M. (2016). Artificial neural network based wind speed and power forecasting in us wind energy farms. In *1st IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems*, pages 2435–2438, São Paulo, Brasil.
- Wagstaff, K., C. C. R. S. S. S. (2001). Constrained k-means clustering with background knowledge. In *Proceedings of the Eighteenth International Conference on Machine Learning*, pages 577–584, Berkeley, California.
- Wang, X., G. P. H. X. (2011). A review of wind power forecasting models. *Energy Procedia*, 12(12):770–778.
- Werbos, P. (1974). *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Ph.d. dissertation, Harvard University, Cambridge, England.
- Widrow, B. and Hoff, M. (1960). Adaptive switching circuits. *IRE WESCON Convention Record*, 39(4):94–112.

- Widrow, B., Y. M. J. G. and Goldstein, G. (1962). Generalization and information storage in networks of adaline neurons. *Self Organizing Systems*, 39(4):435–4611.
- Willmot, K. M. (2005). Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Bulletin of the American Meteorological Society*, 30(1):79–82.
- WRF-ARW (2019). Wrf-arw online tutorial, @BOOKLET.
- Wu, Q.Z, L. Y. J. L. J. B. (1993). Online recognition of limited vocabulary chinese character using multiple convulational network. In *IEEE International Symposium on Circuits and Systems*, pages 2435–2438, London.
- Yadav, N., Y. A. K. M. (2004). *An Introduction to Neural Network Methods of Differential Equations*. Springer, Warsaw.
- Zemamou, M., A. M. T. A. (2017). Review of savonius wind turbine design and performance. *Energy Procedia*, 141(1):383–388.
- Zhao, P., W. J. X. J. D. Y. S. Y.-Y. J. (2012). Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in china. *Renewable Energy*, 43(43):234–241.
- Zurada, J. (1992). *Introduction to Artificial Neural Systems*. West Publishing Company, New York.

APÉNDICES

Apéndice 1

Análisis Cluster - Parametrización Mellor-Yamada-Janjic

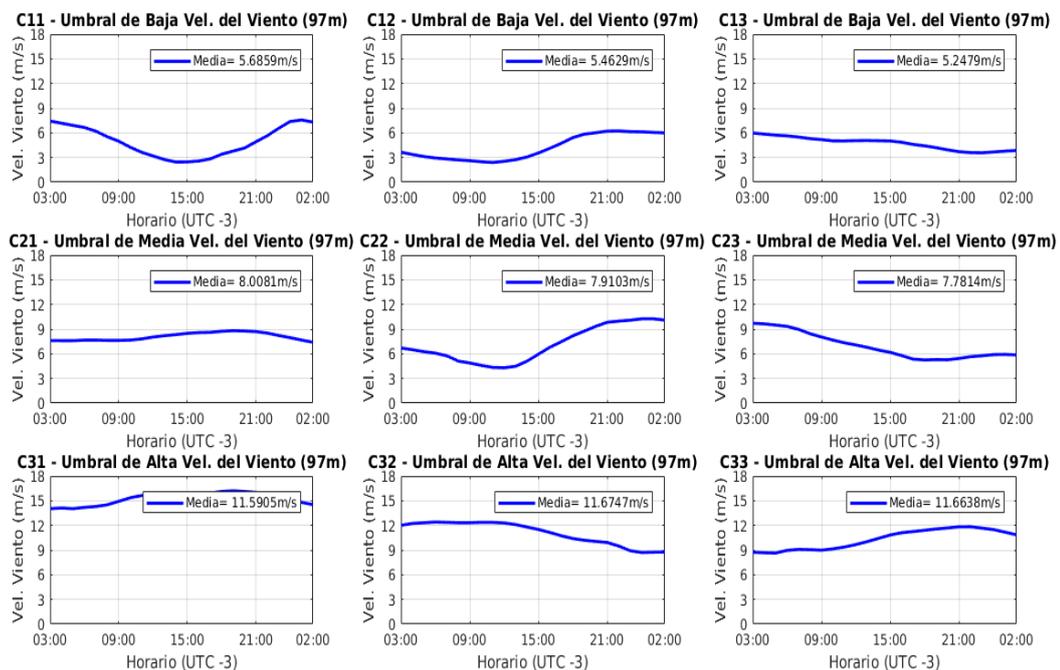


Figura 1.1: Umbrales de velocidad del viento para la torre de Caracoles, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

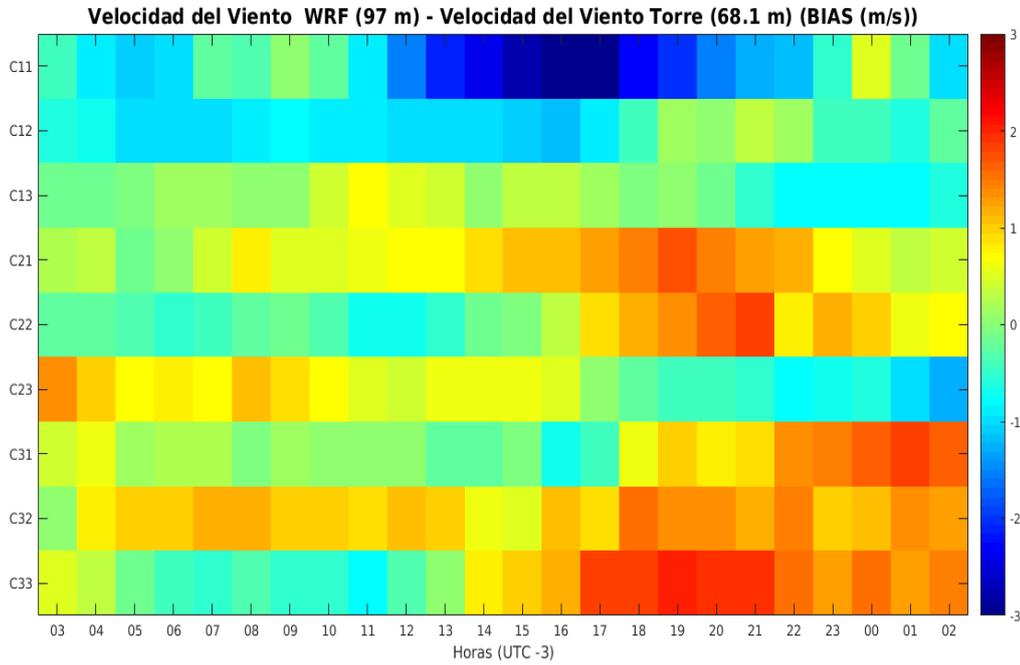


Figura 1.2: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Caracoles, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

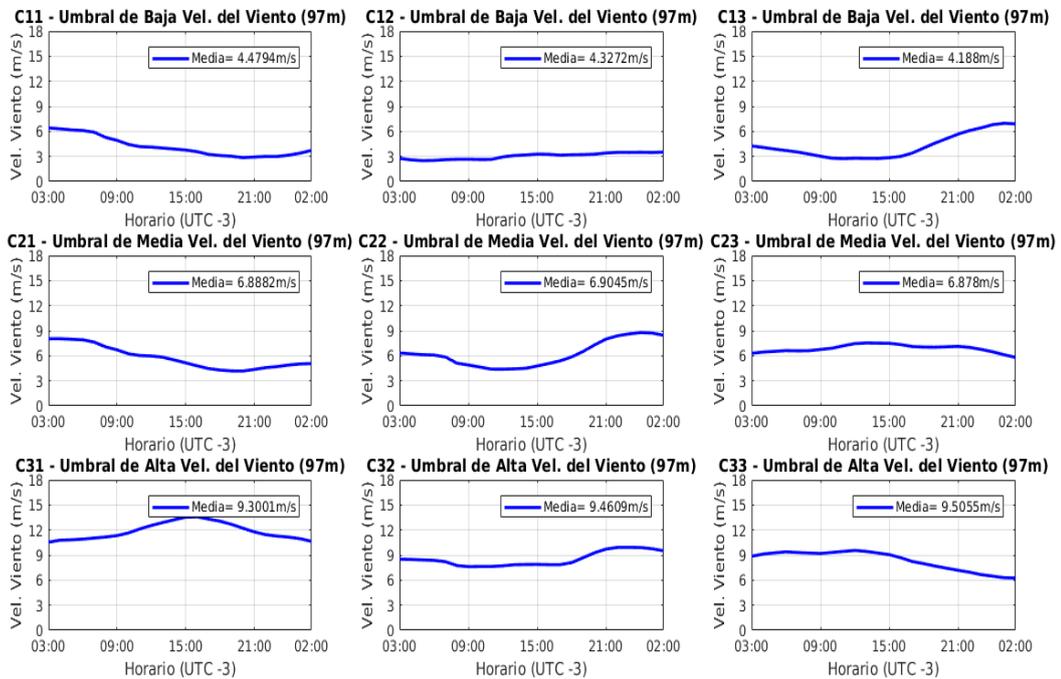


Figura 1.3: Umbrales de velocidad del viento para la torre Colonia Arias, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

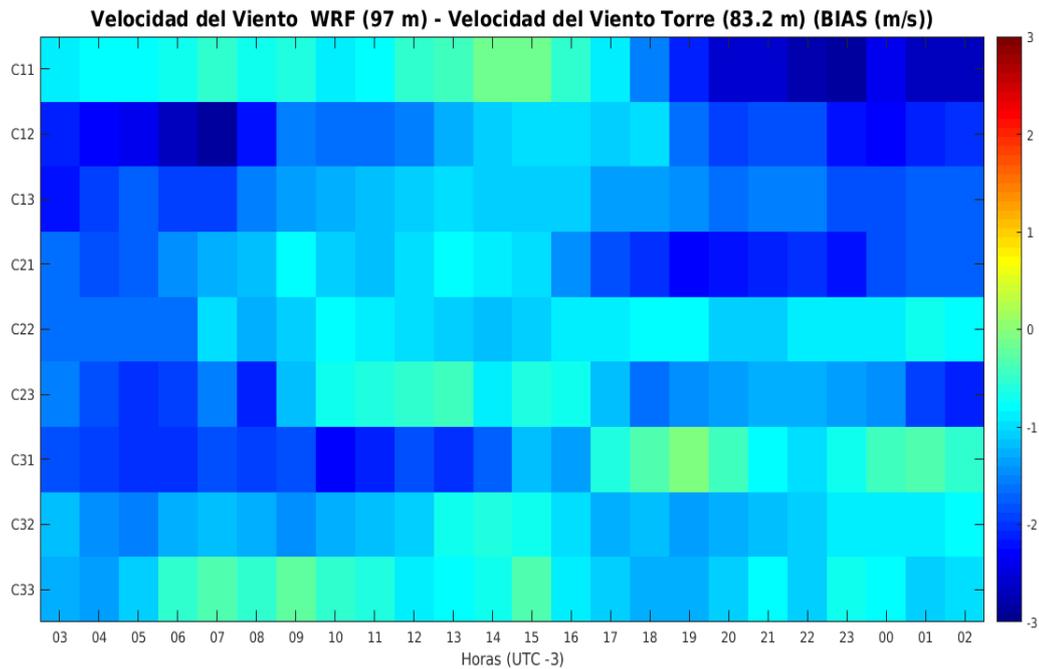


Figura 1.4: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Arias, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

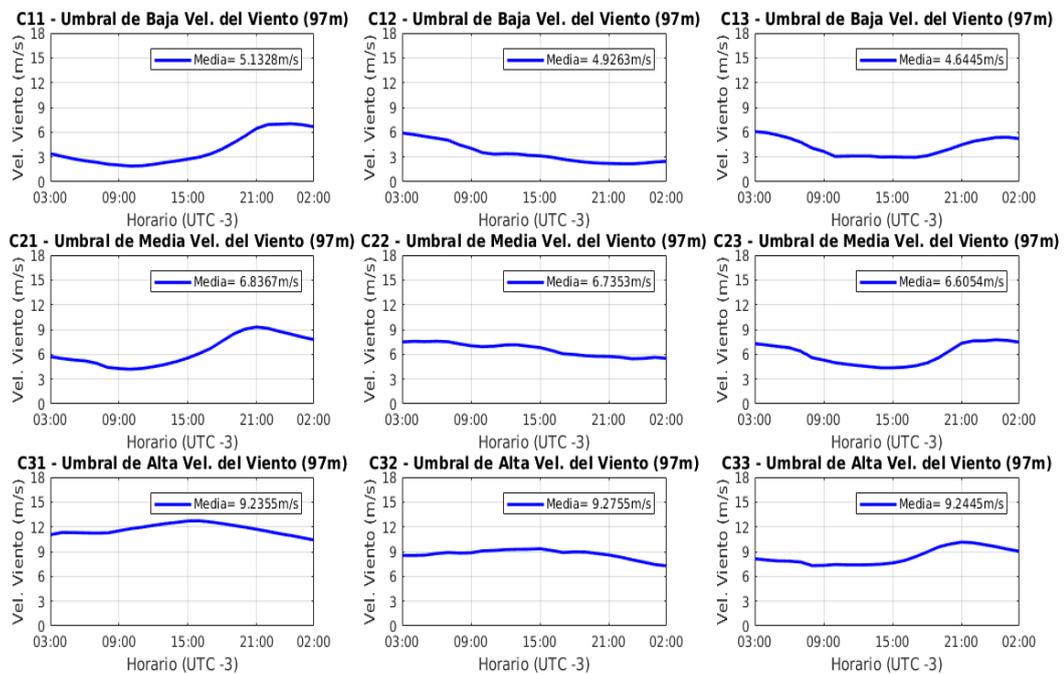


Figura 1.5: Umbrales de velocidad del viento para la torre Colonia Otamendi, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

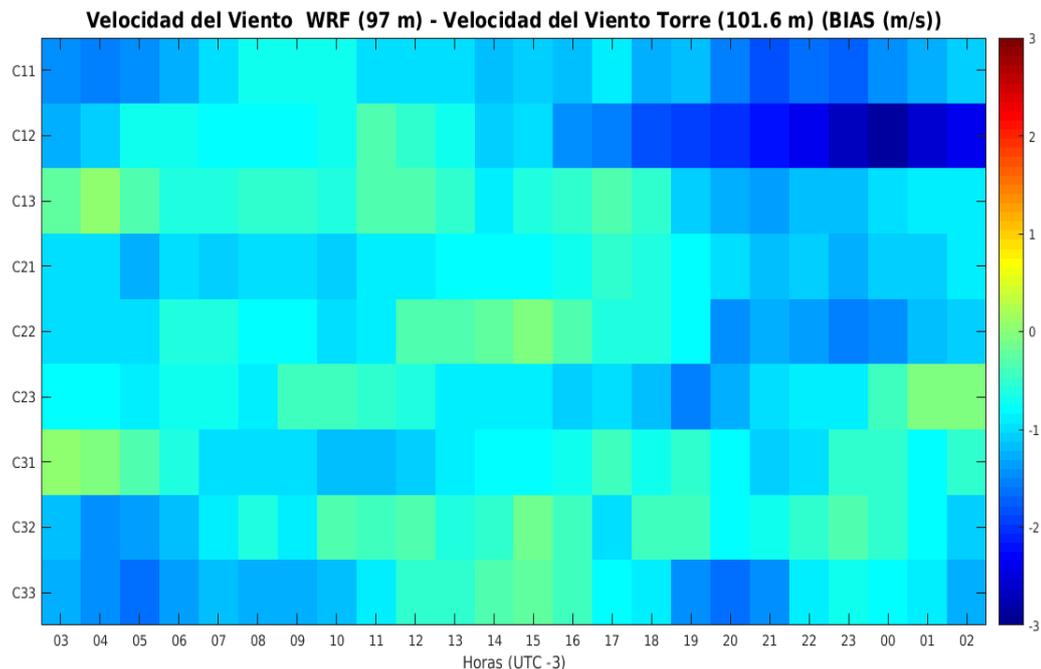


Figura 1.6: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Arias, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

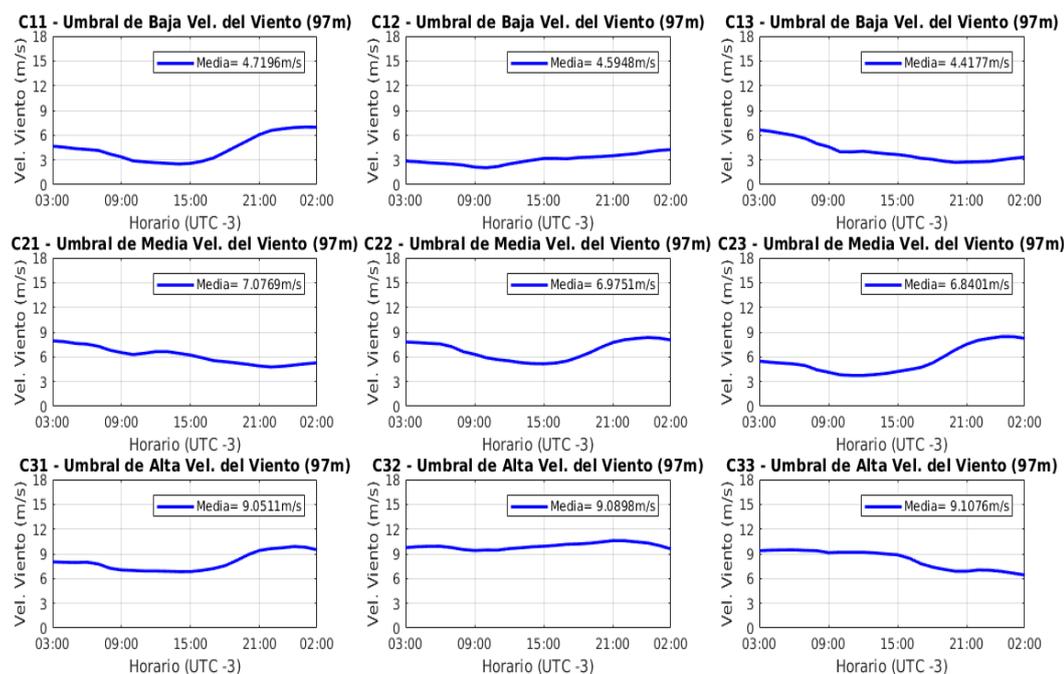


Figura 1.7: Umbrales de velocidad del viento para la torre Colonia Terra, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

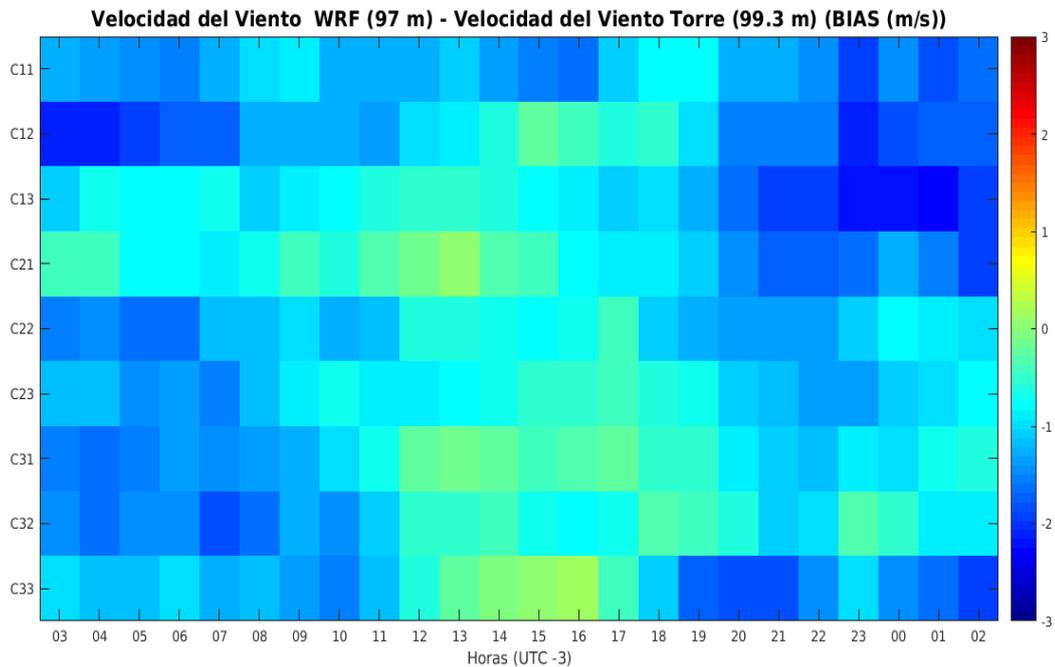


Figura 1.8: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Terra, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

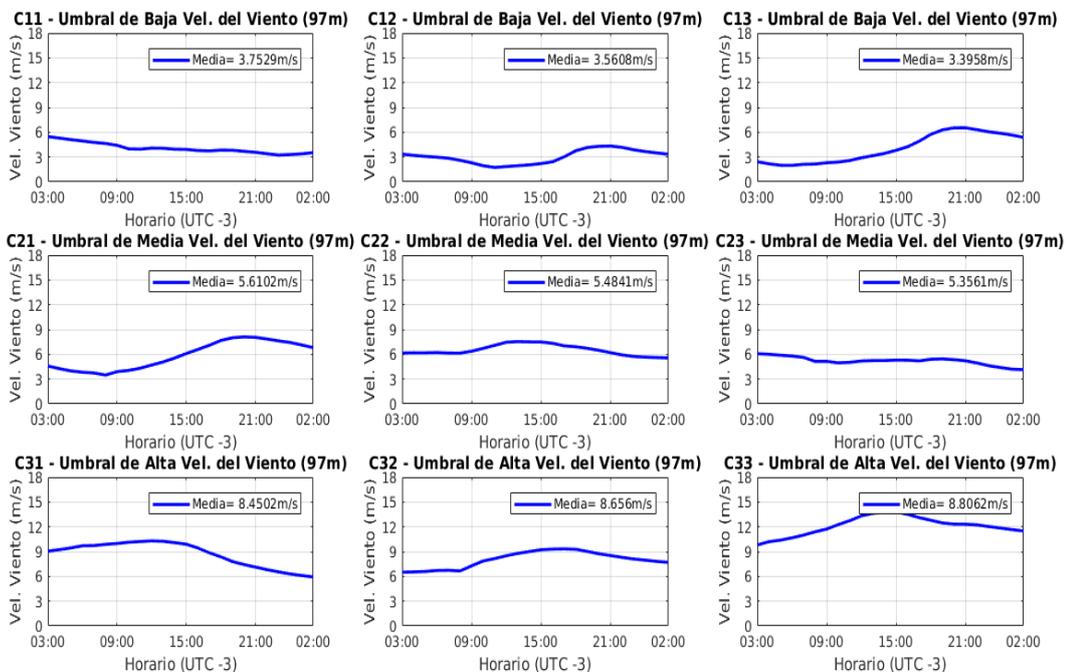


Figura 1.9: Umbrales de velocidad del viento para la torre Lascano, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

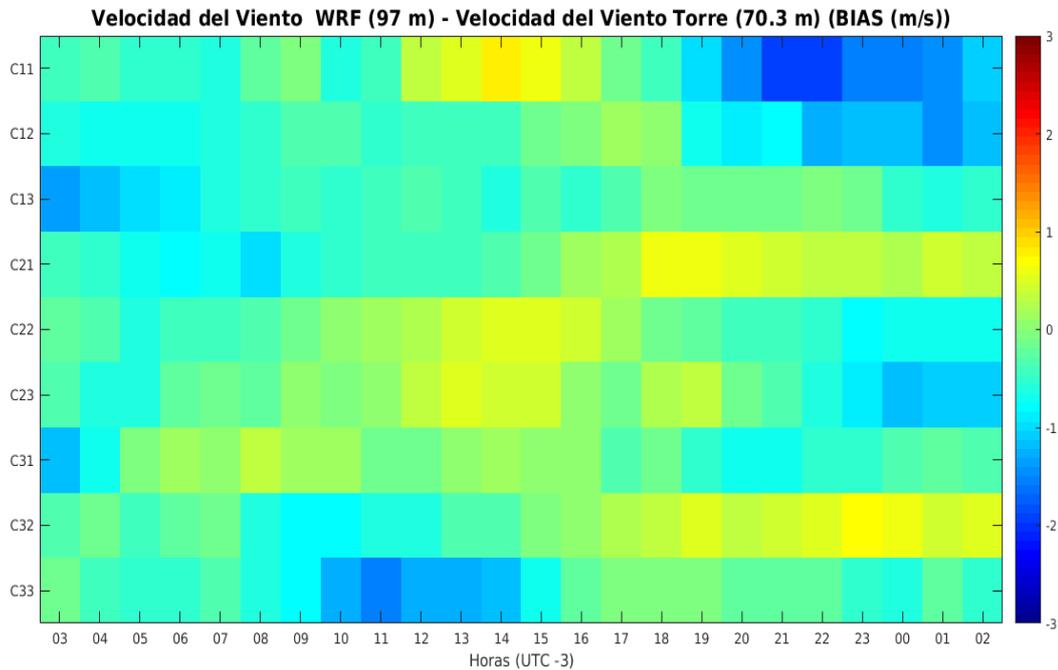


Figura 1.10: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Lascano, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

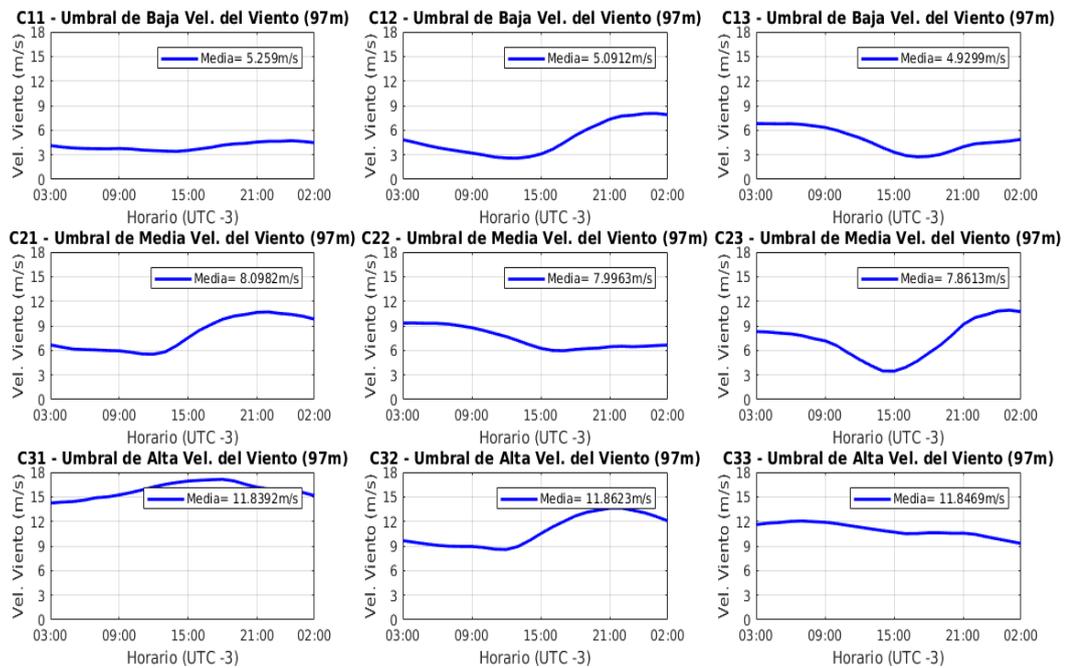


Figura 1.11: Umbrales de velocidad del viento para la torre Mc Meekan, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

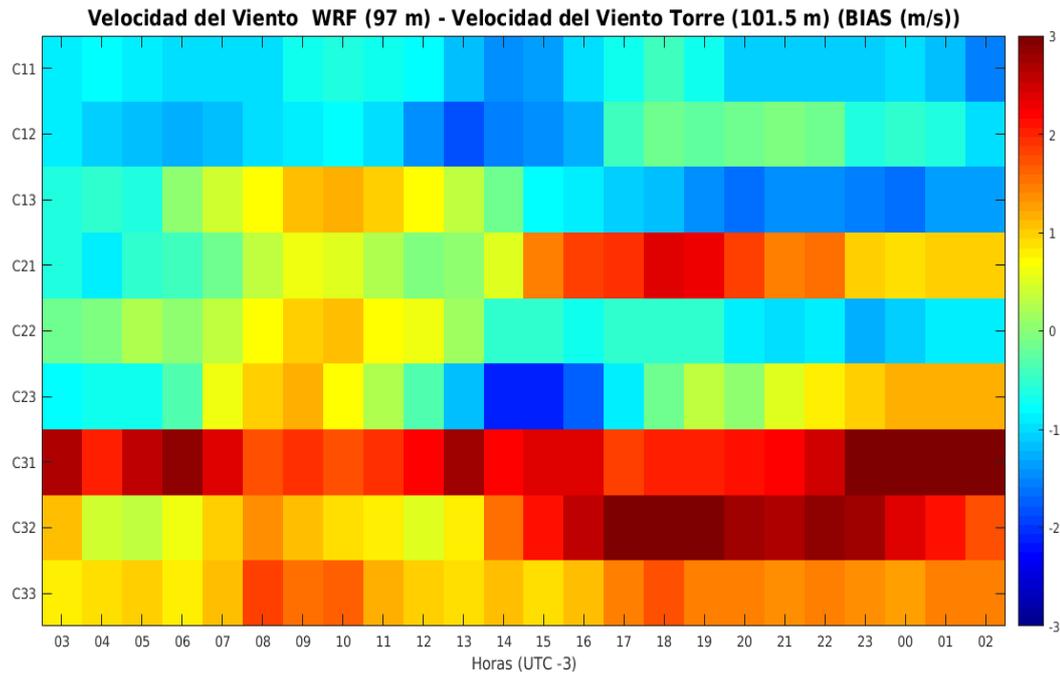


Figura 1.12: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Mc Meekan, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

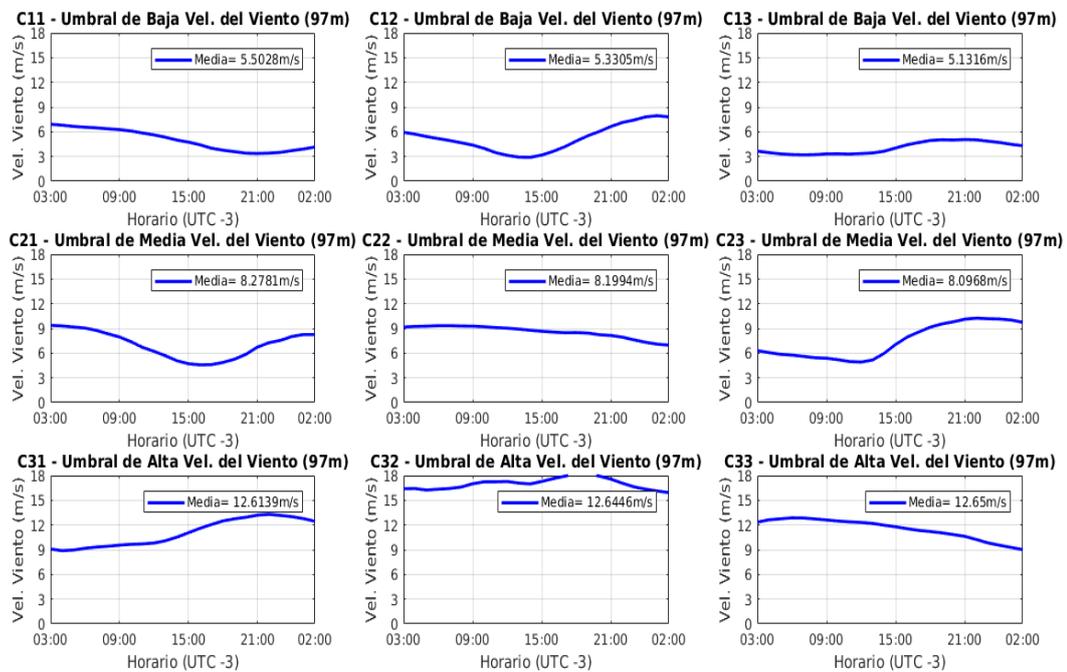


Figura 1.13: Umbrales de velocidad del viento para la torre Paloma Santa Rita, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

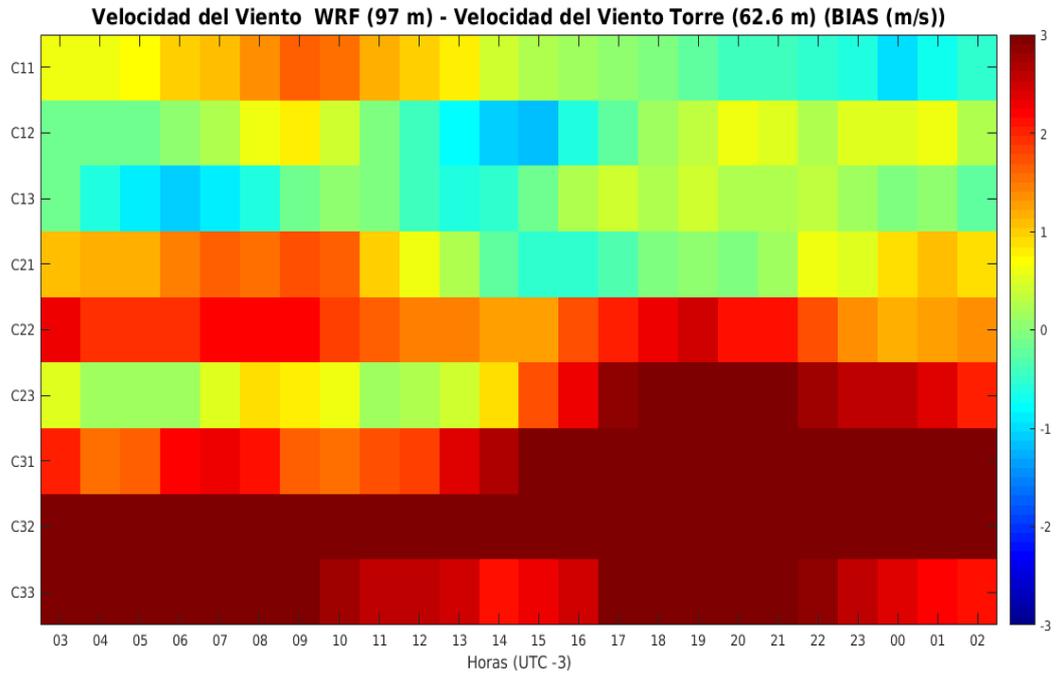


Figura 1.14: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Paloma Santa Rita, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

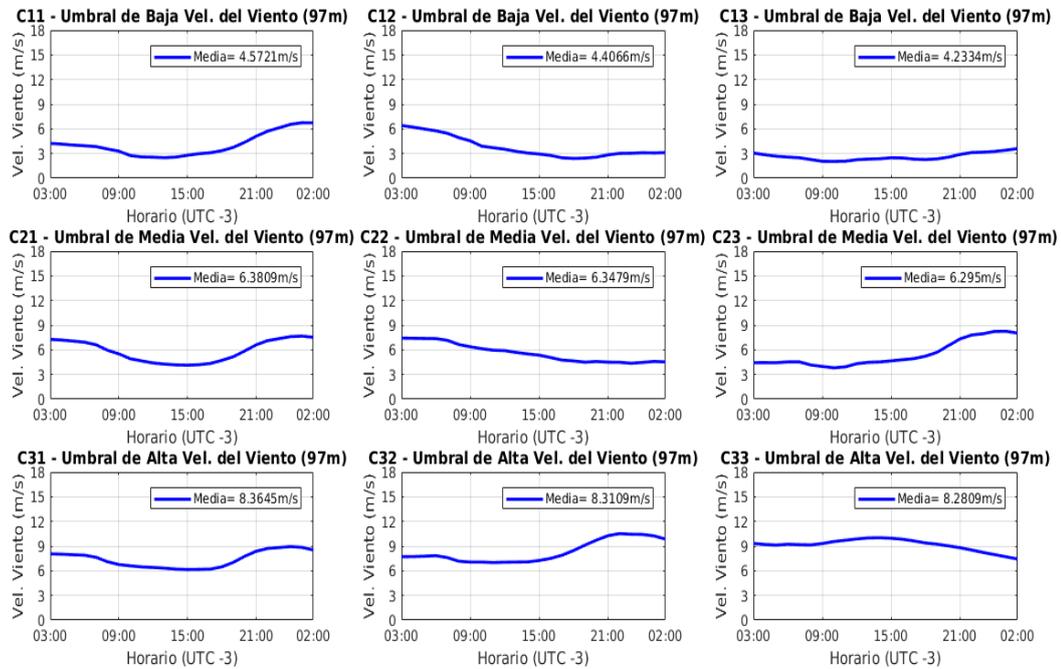


Figura 1.15: Umbrales de velocidad del viento para la torre Piedra de Afilar, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

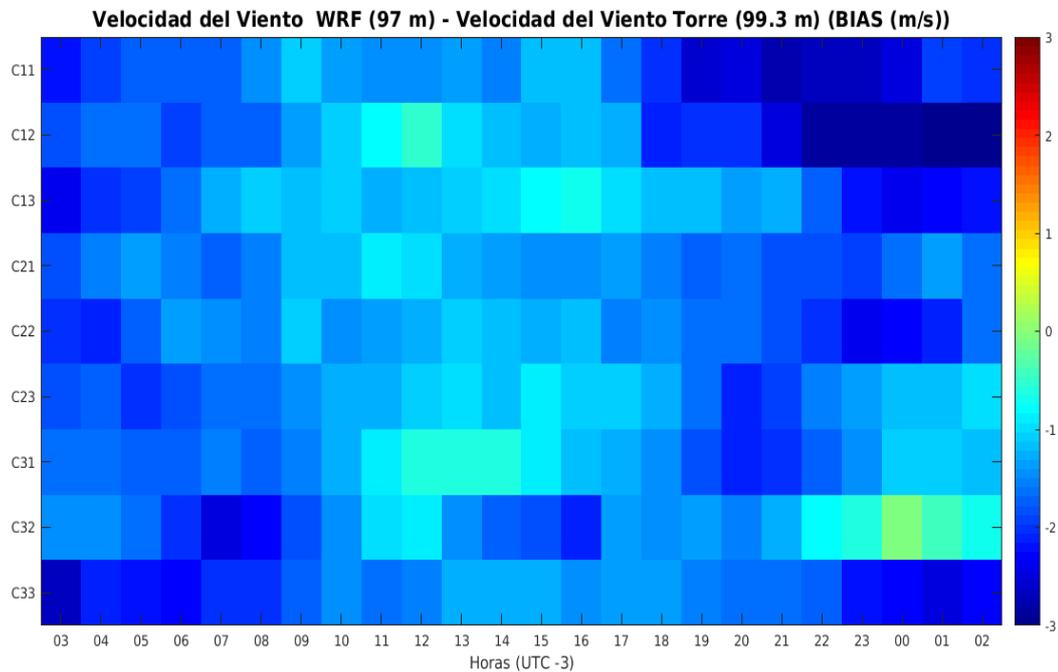


Figura 1.16: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Piedra de Afilar, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

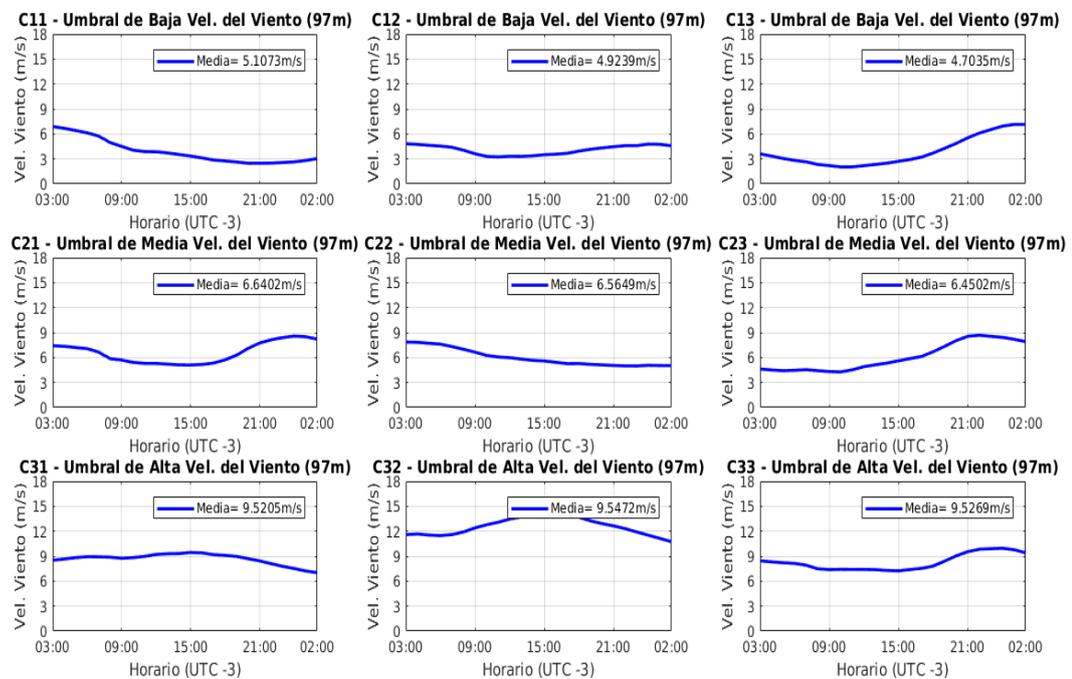


Figura 1.17: Umbrales de velocidad del viento para la torre Piedra Sola, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

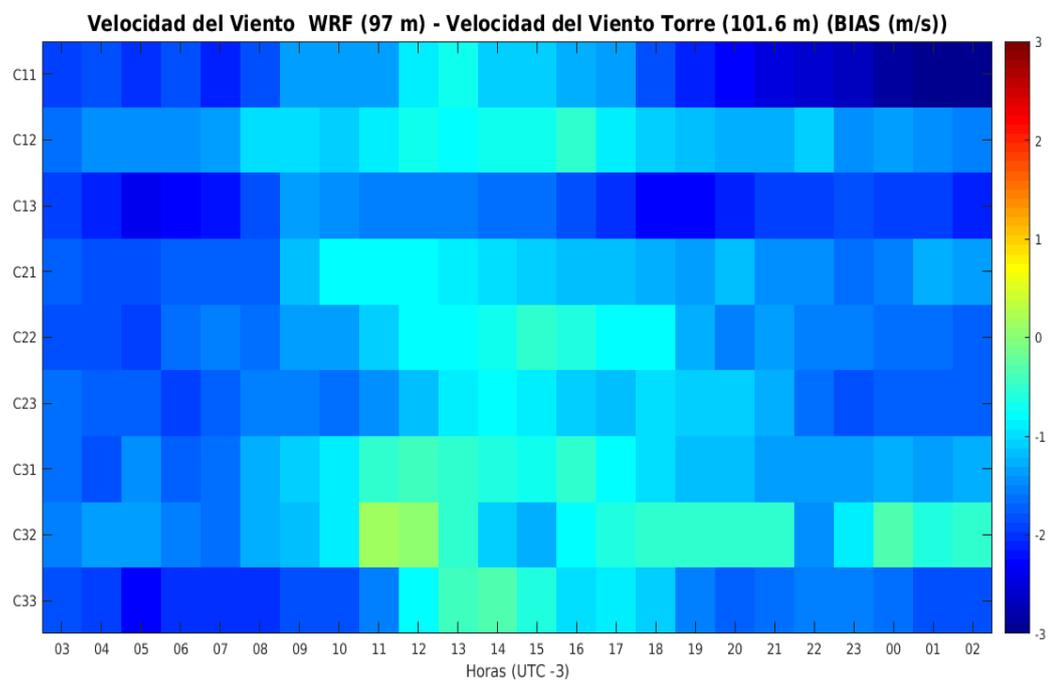


Figura 1.18: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Piedra Sola, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

Apéndice 2

Continuación de Análisis Cluster - Parametrización Mellor-Yamada-Janjic

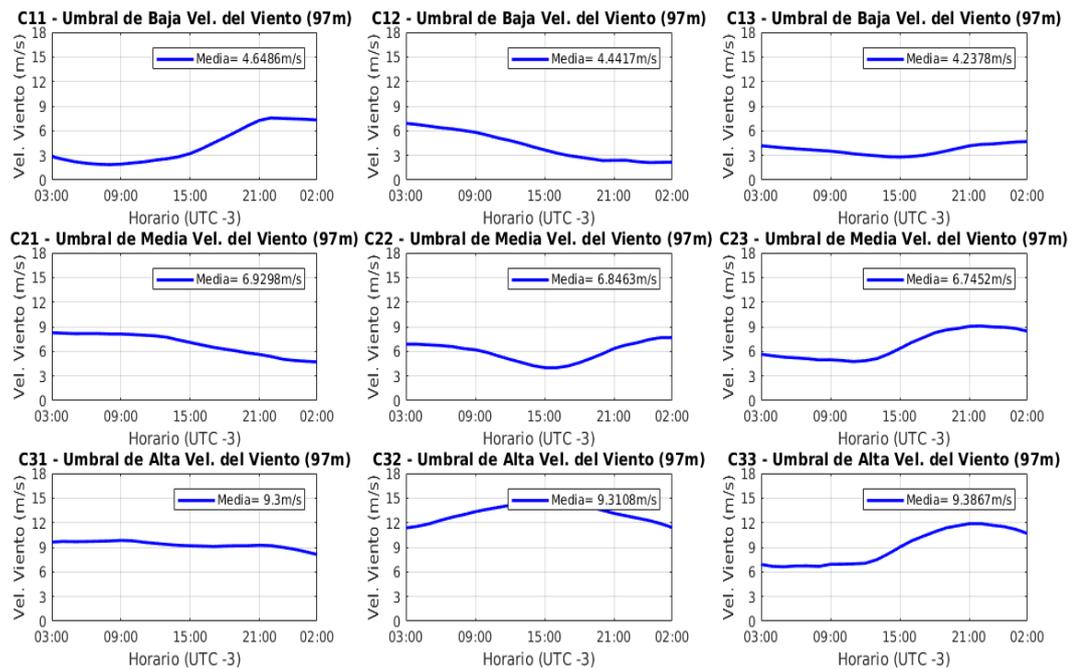


Figura 2.1: Umbrales de velocidad del viento para la torre Rosendo Mendoza, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

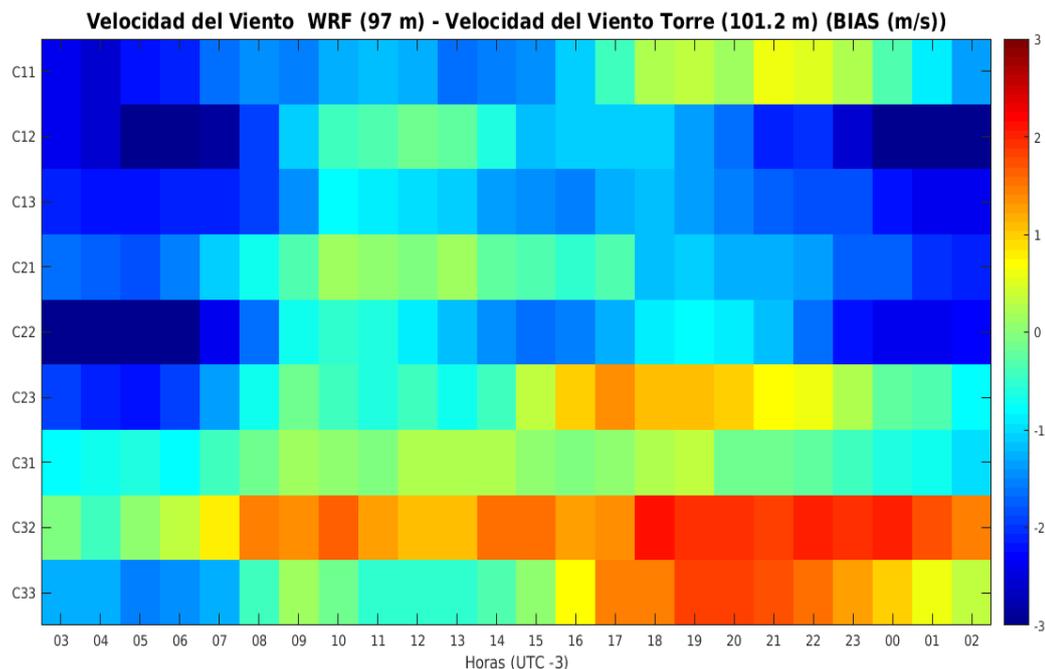


Figura 2.2: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Rosendo Mendoza, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

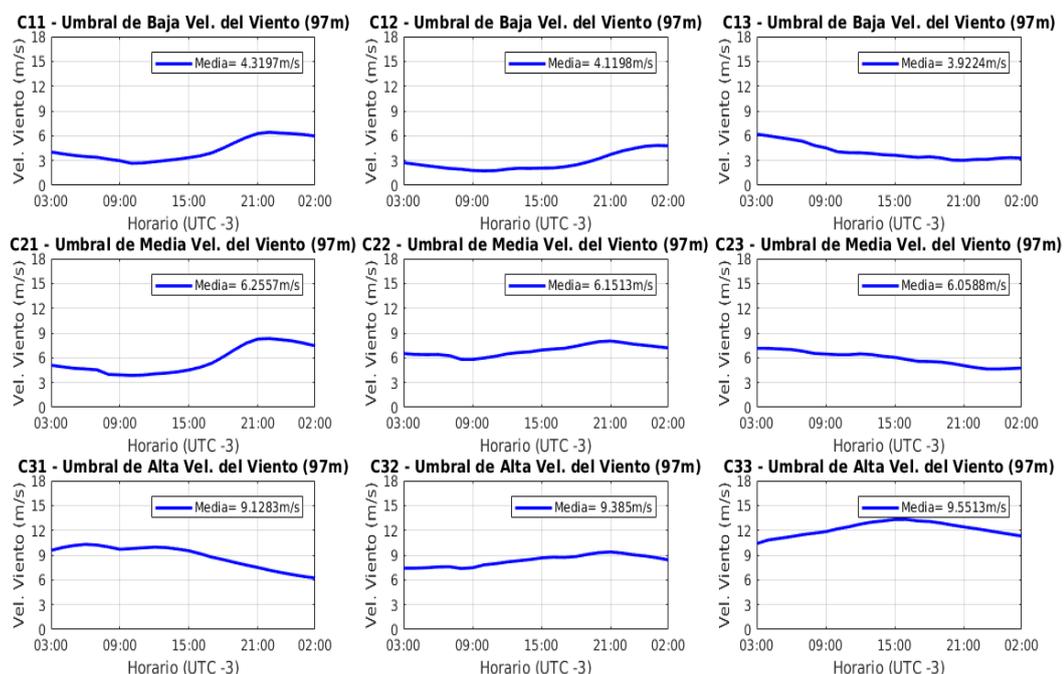


Figura 2.3: Umbrales de velocidad del viento para la torre Valentines, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

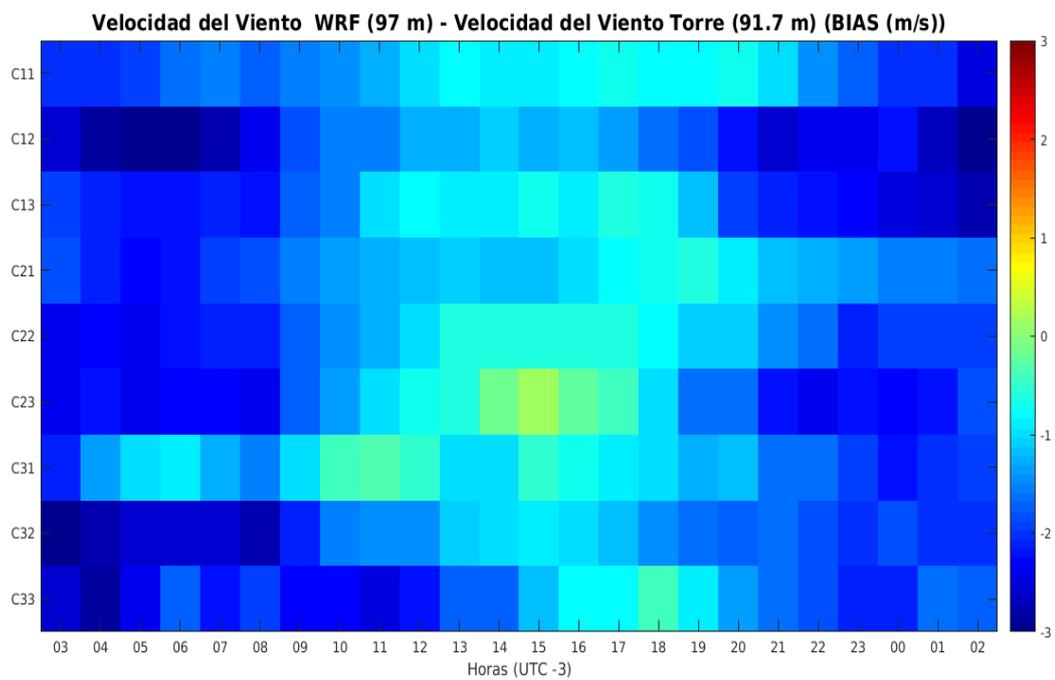


Figura 2.4: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Valentines, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Mellor-Yamada-Janjic.

Apéndice 3

Análisis Cluster - Parametrización Yonsei University

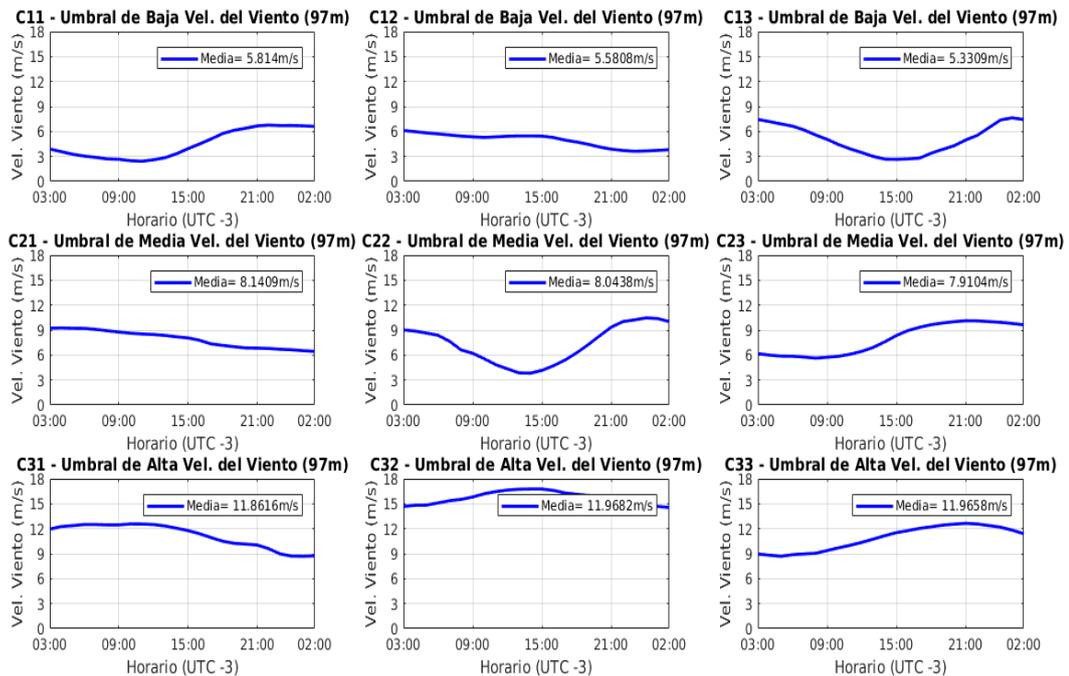


Figura 3.1: Umbrales de velocidad del viento para la torre Caracoles, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

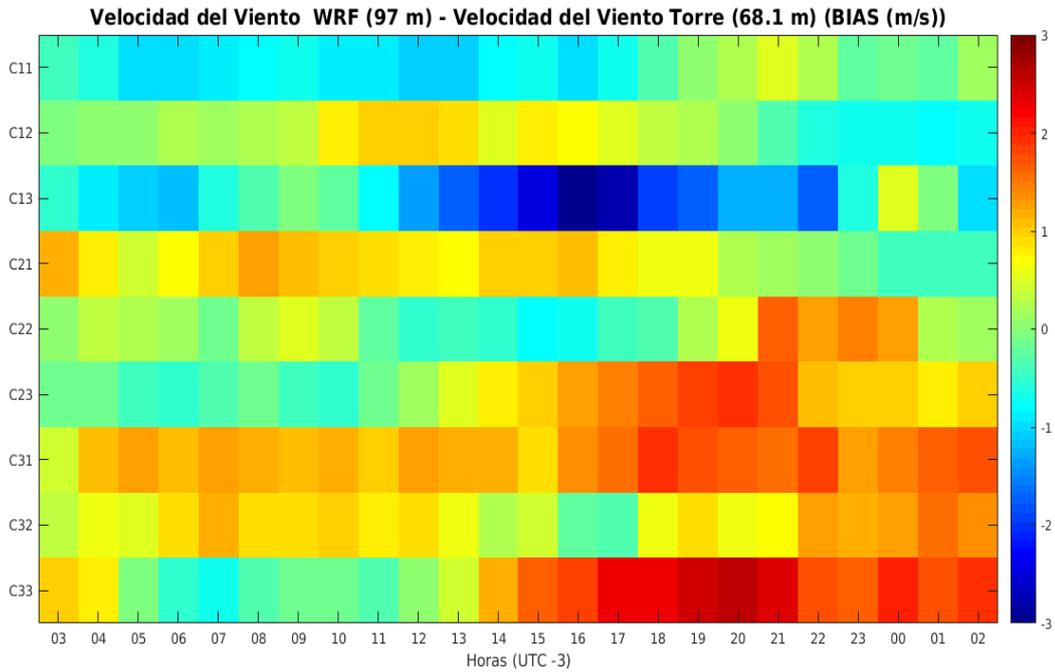


Figura 3.2: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Caracoles, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

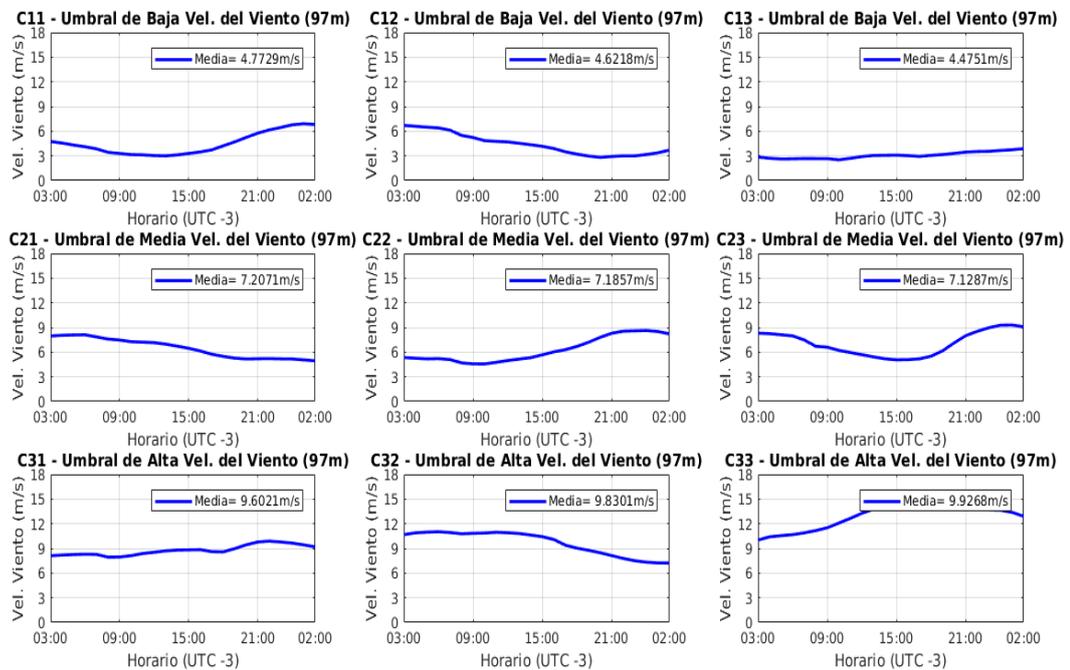


Figura 3.3: Umbrales de velocidad del viento para la torre Colonia Arias, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

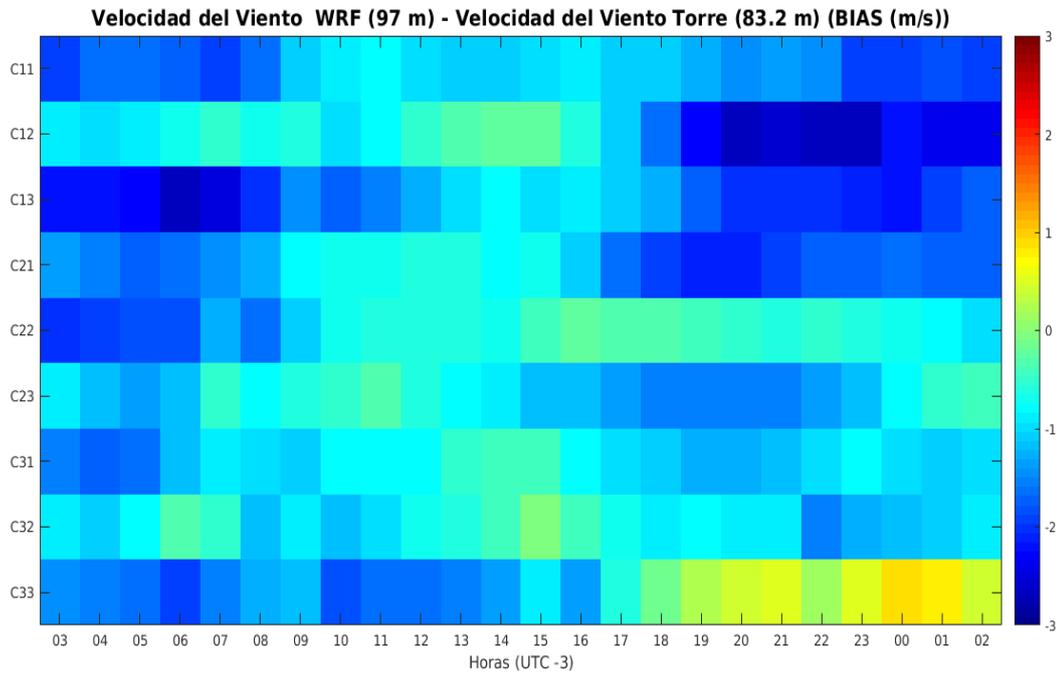


Figura 3.4: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Arias, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

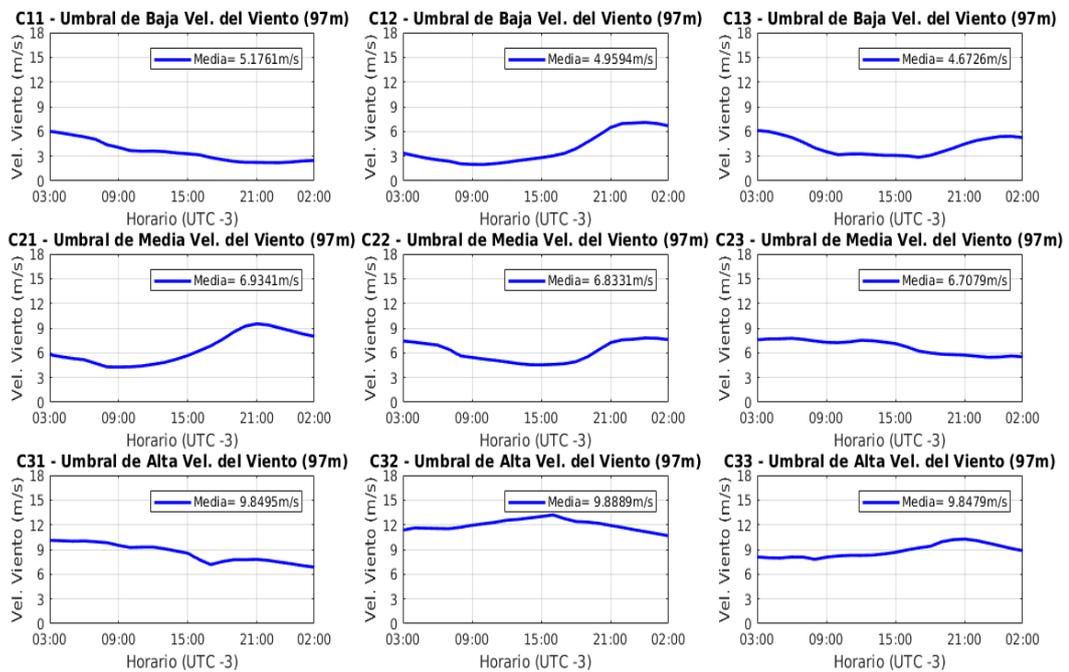


Figura 3.5: Umbrales de velocidad del viento para la torre Colonia Otamendi, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

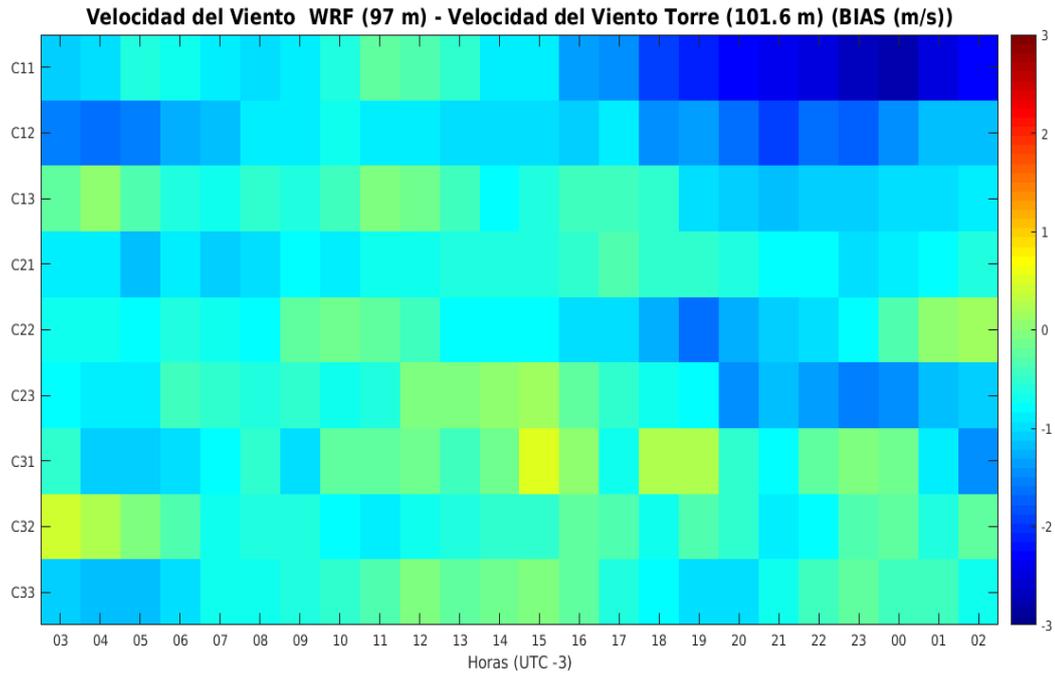


Figura 3.6: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Otamendi, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

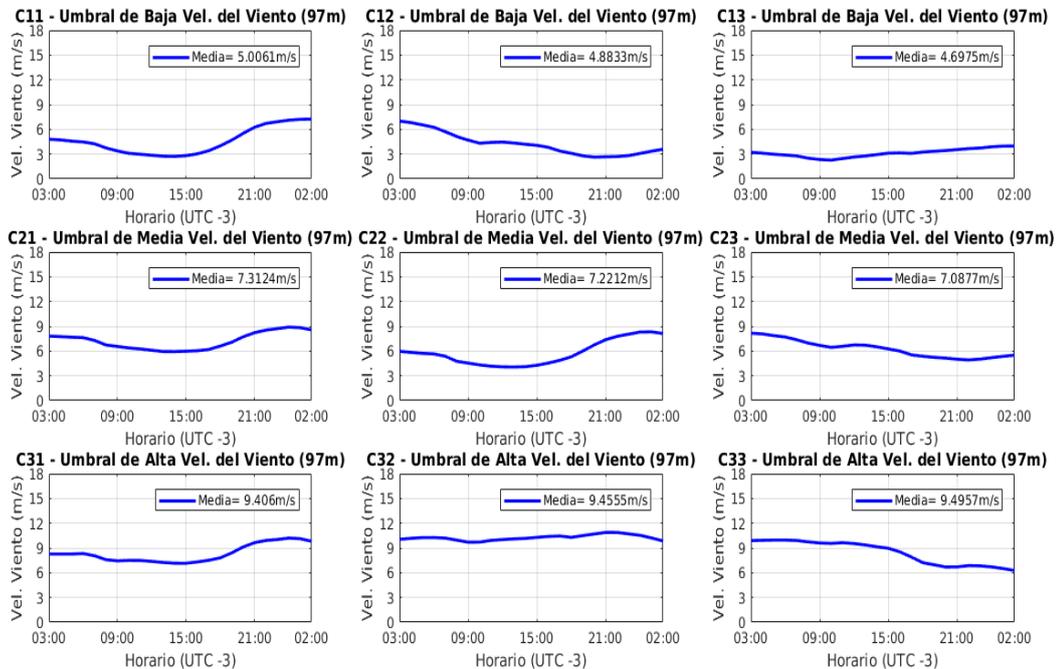


Figura 3.7: Umbrales de velocidad del viento para la torre Colonia Terra, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

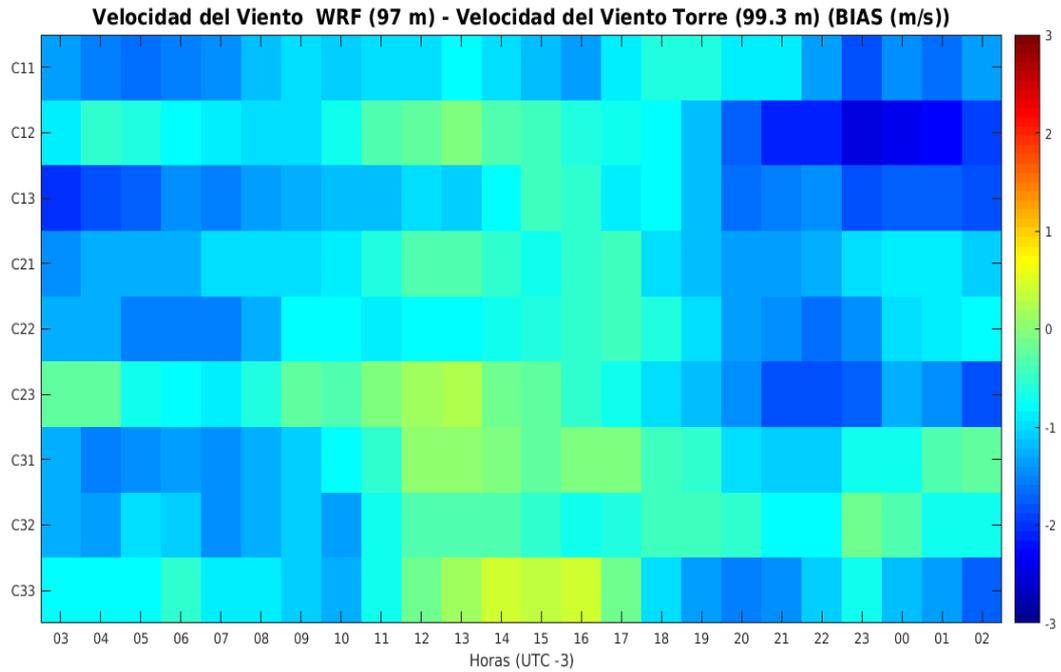


Figura 3.8: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Colonia Terra, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

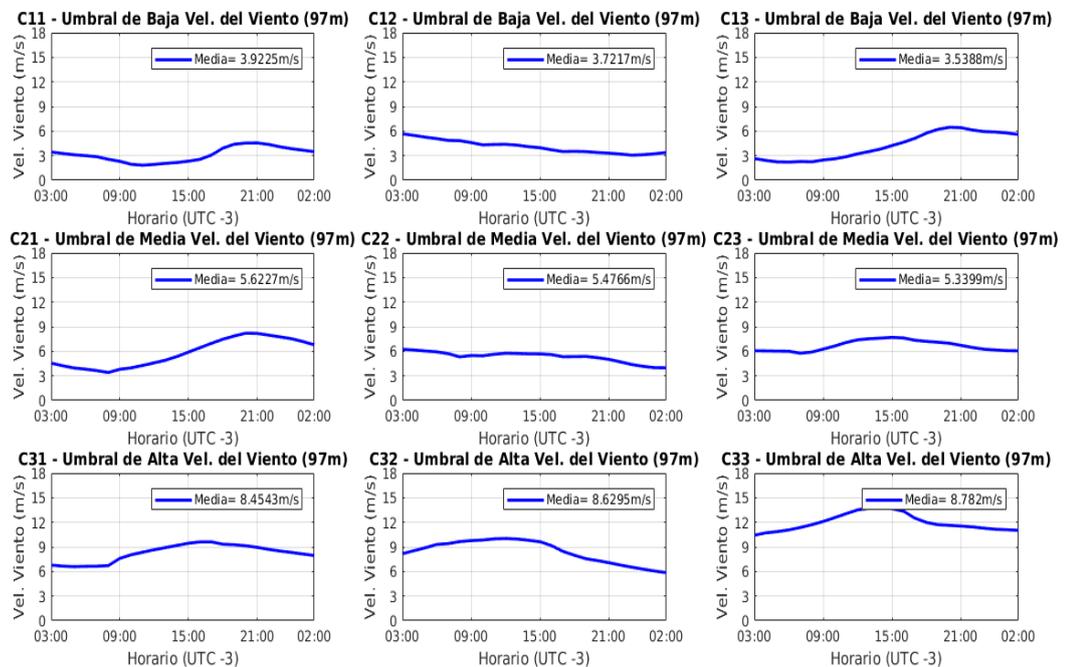


Figura 3.9: Umbrales de velocidad del viento para la torre Lascano, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

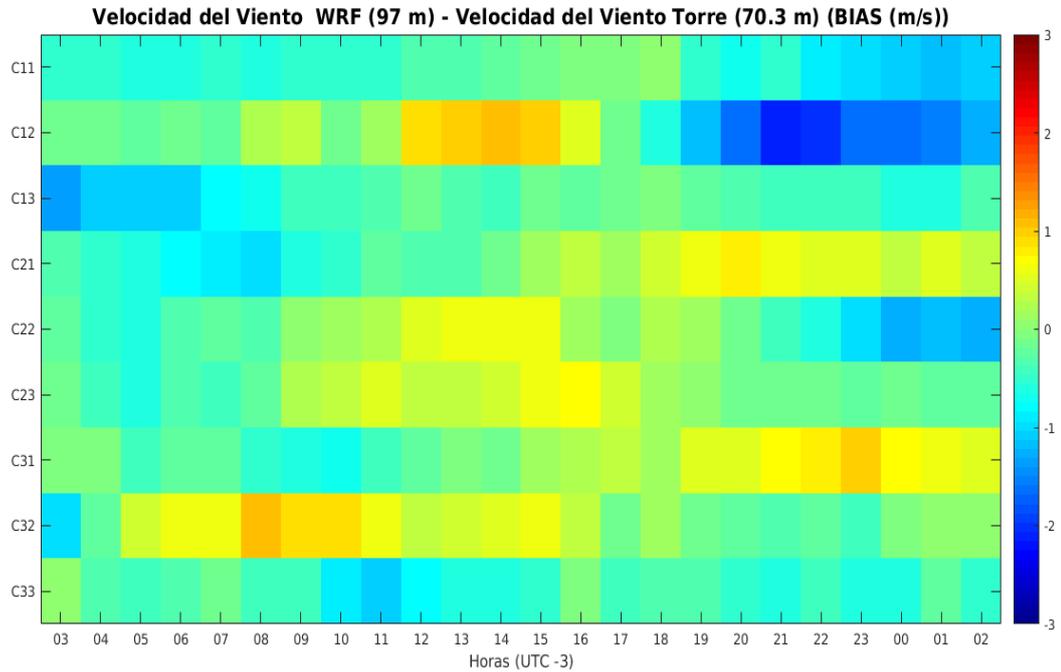


Figura 3.10: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Lascano, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

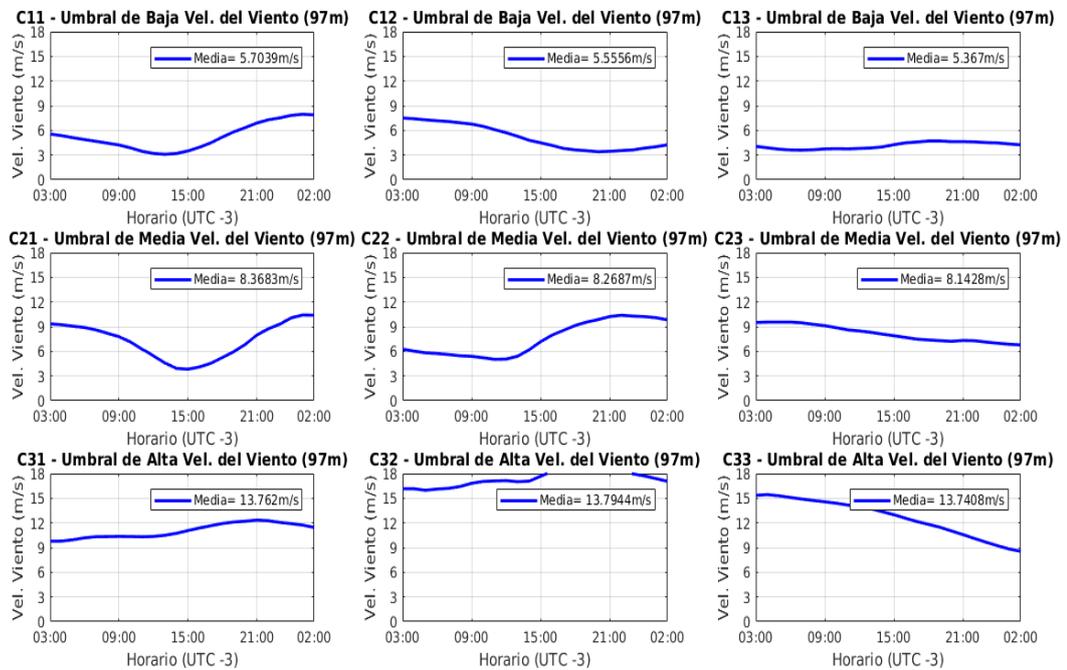


Figura 3.11: Umbrales de velocidad del viento para la torre Mc Meekan, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

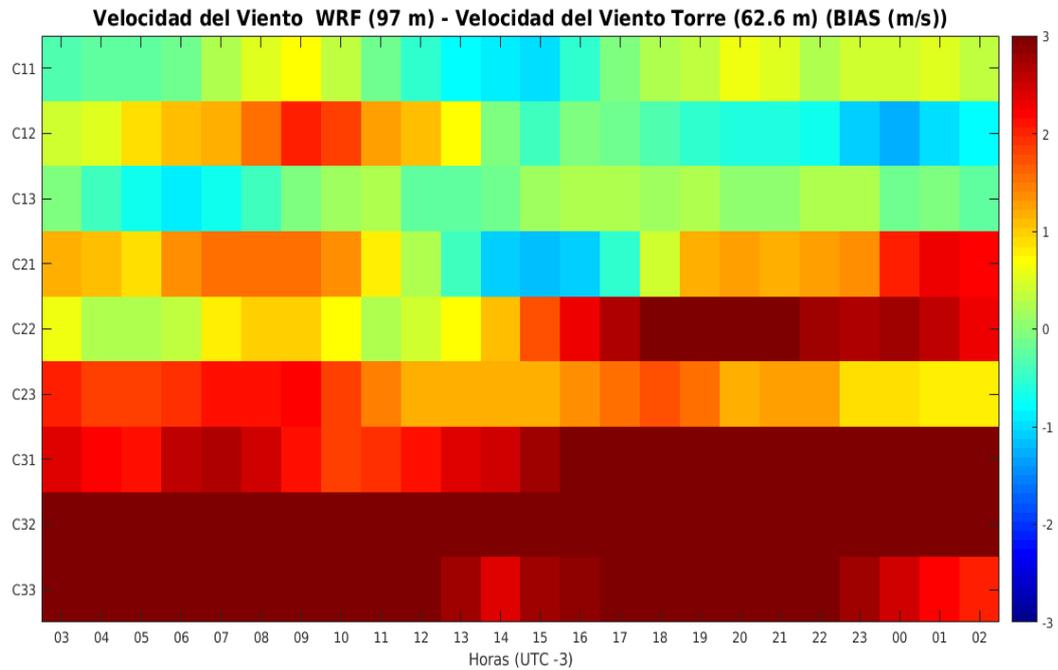


Figura 3.12: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Mc Meekan, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

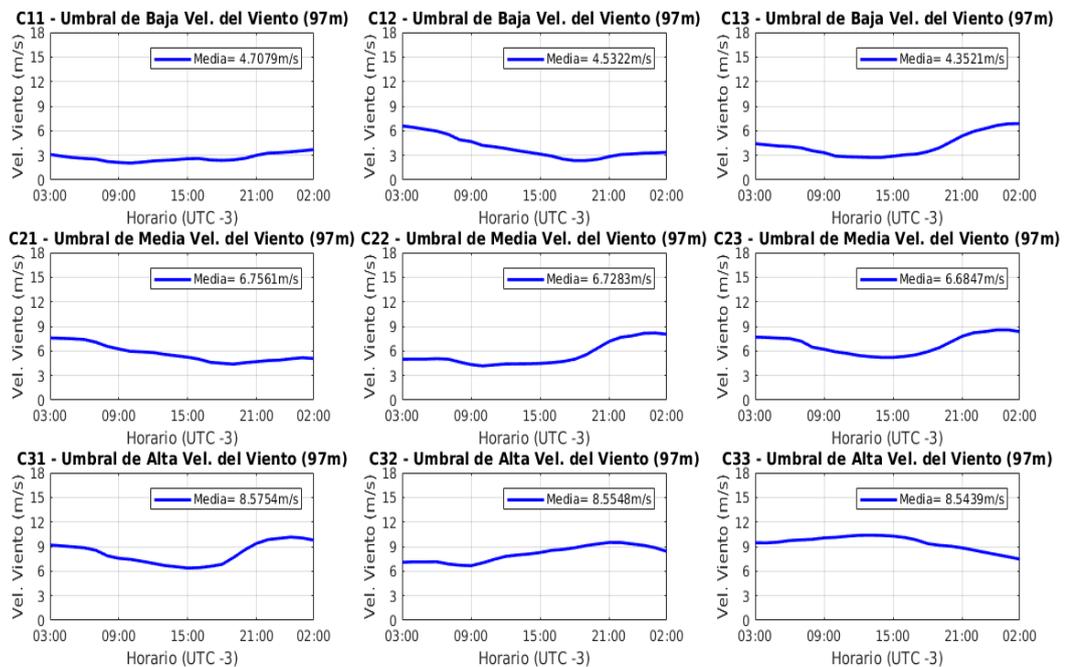


Figura 3.13: Umbrales de velocidad del viento para la torre Paloma Santa Rita, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

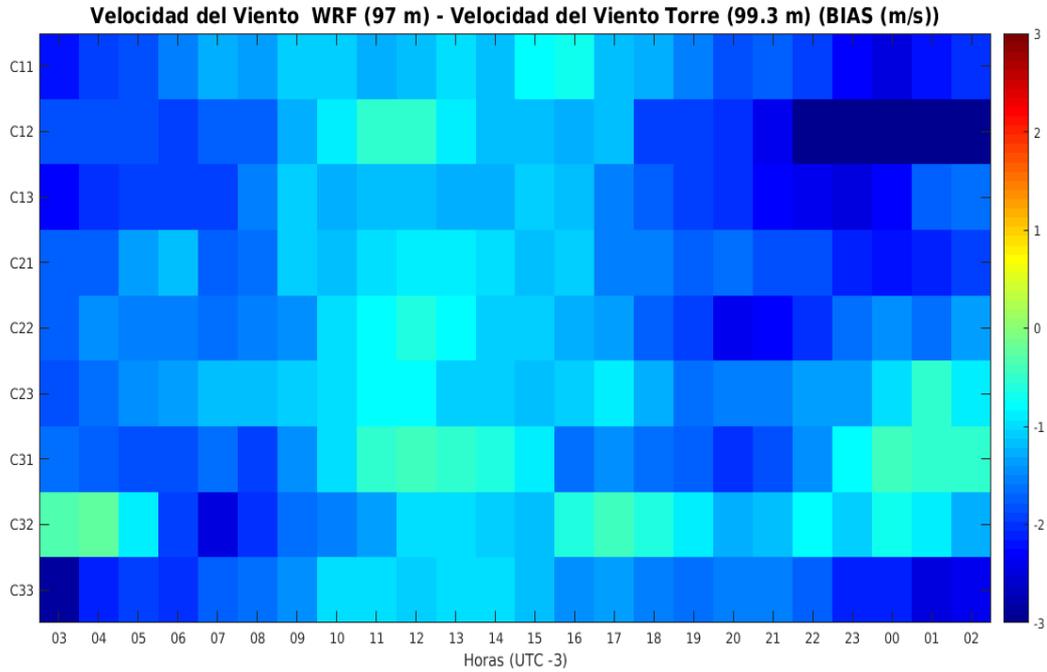


Figura 3.14: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Paloma Santa Rita, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

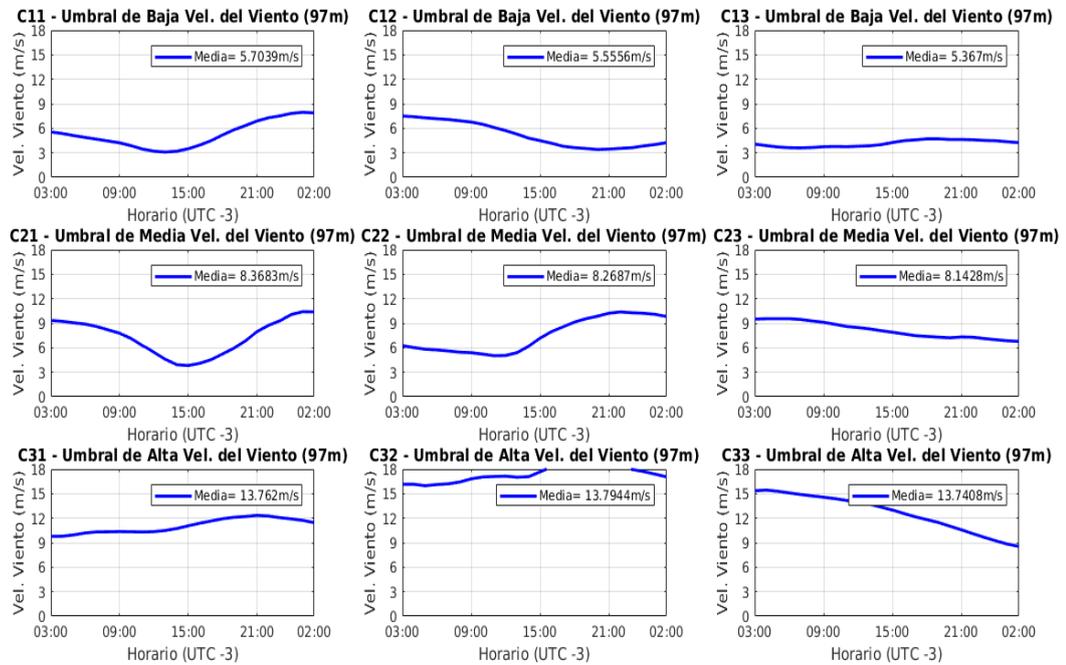


Figura 3.15: Umbrales de velocidad del viento para la torre Piedras de Afilar, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

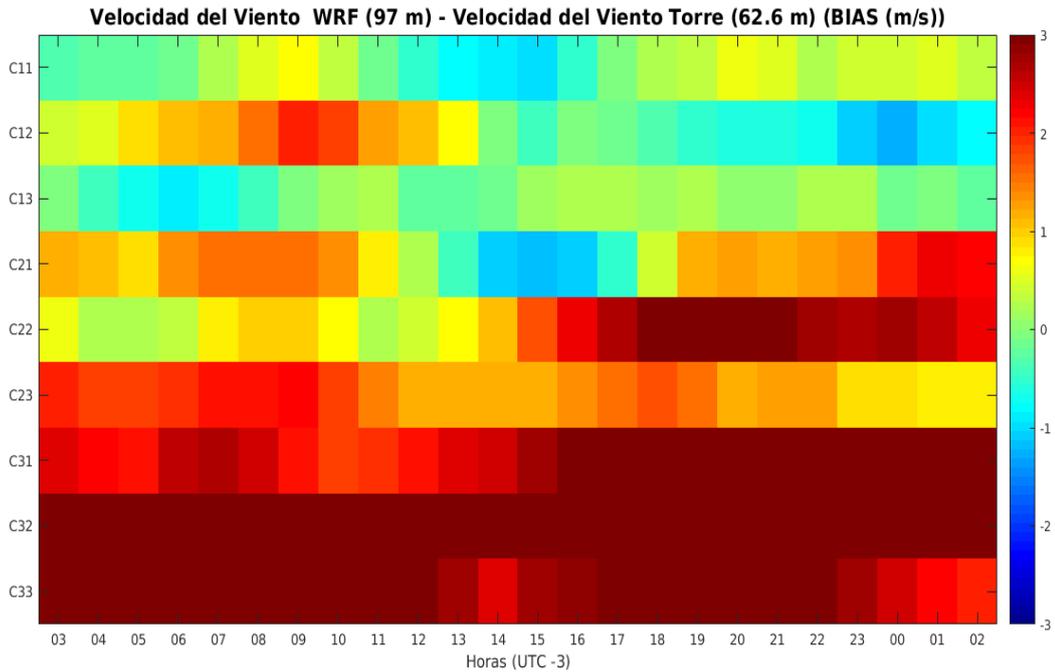


Figura 3.16: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Piedras de Aflar, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

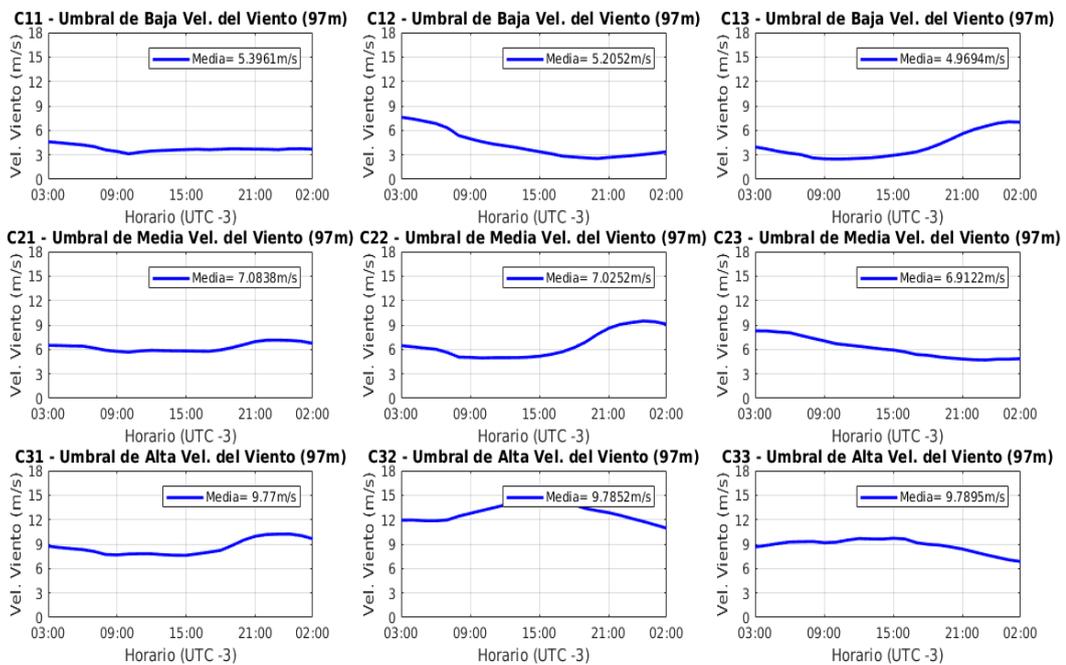


Figura 3.17: Umbrales de velocidad del viento para la torre Piedra Sola, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

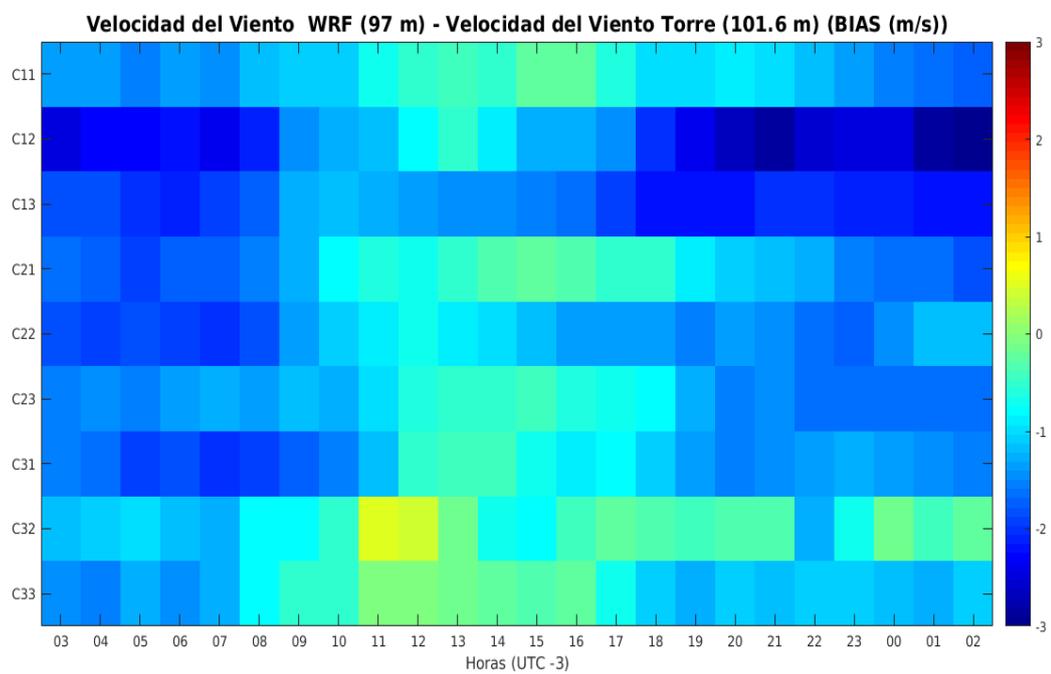


Figura 3.18: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Piedra Sola, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

Apéndice 4

Continuación de Análisis Cluster - Parametrización Yonsei University

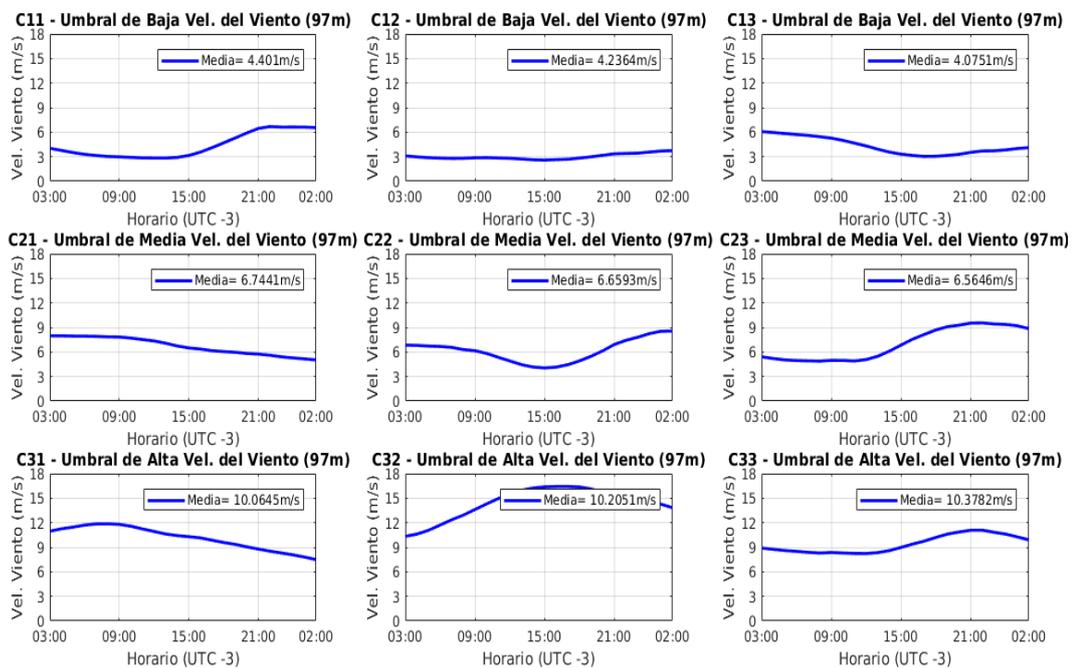


Figura 4.1: Umbrales de velocidad del viento para la torre Rosendo Mendoza, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

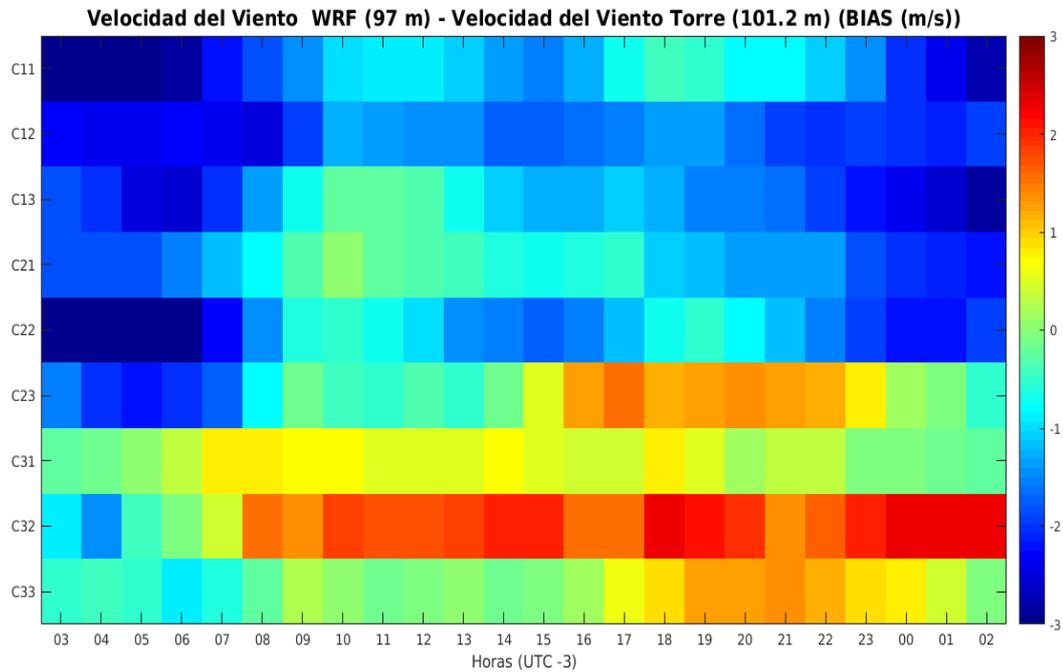


Figura 4.2: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Rosendo Mendoza, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

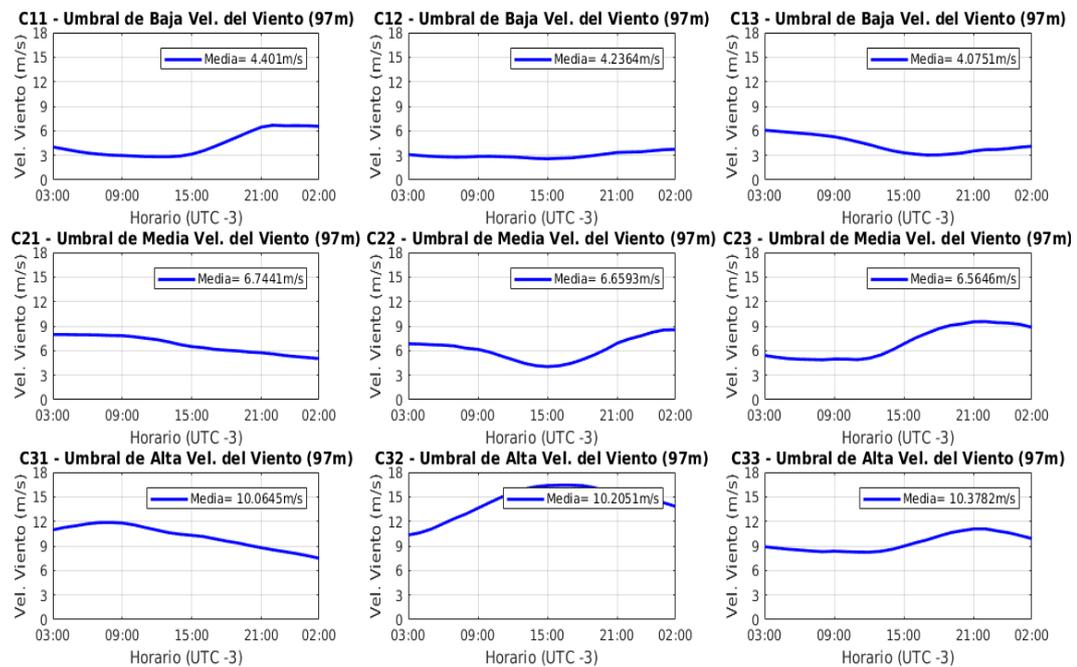


Figura 4.3: Umbrales de velocidad del viento para la torre Rosendo Mendoza, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

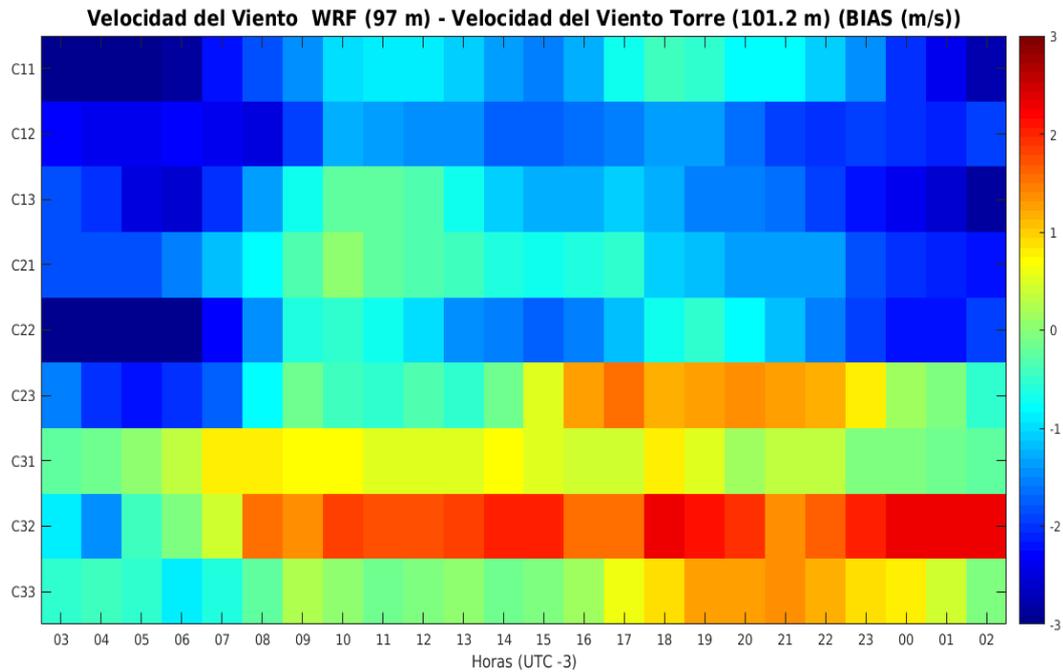


Figura 4.4: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Rosendo Mendoza, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

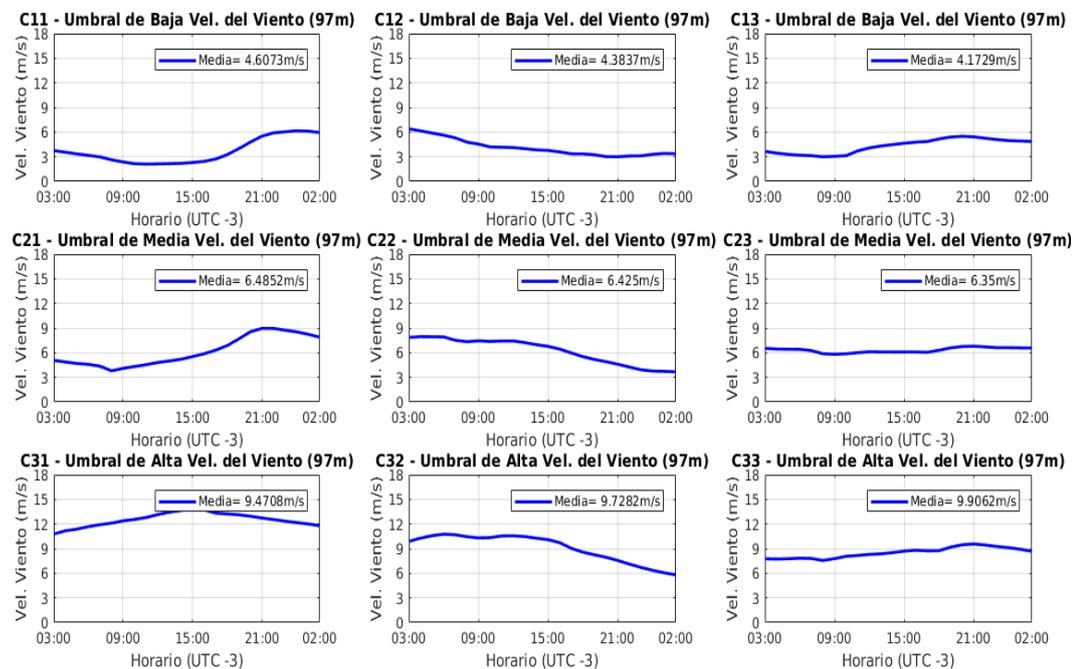


Figura 4.5: Umbrales de velocidad del viento para la torre Valentines, elegidos de acuerdo a la simulación del modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

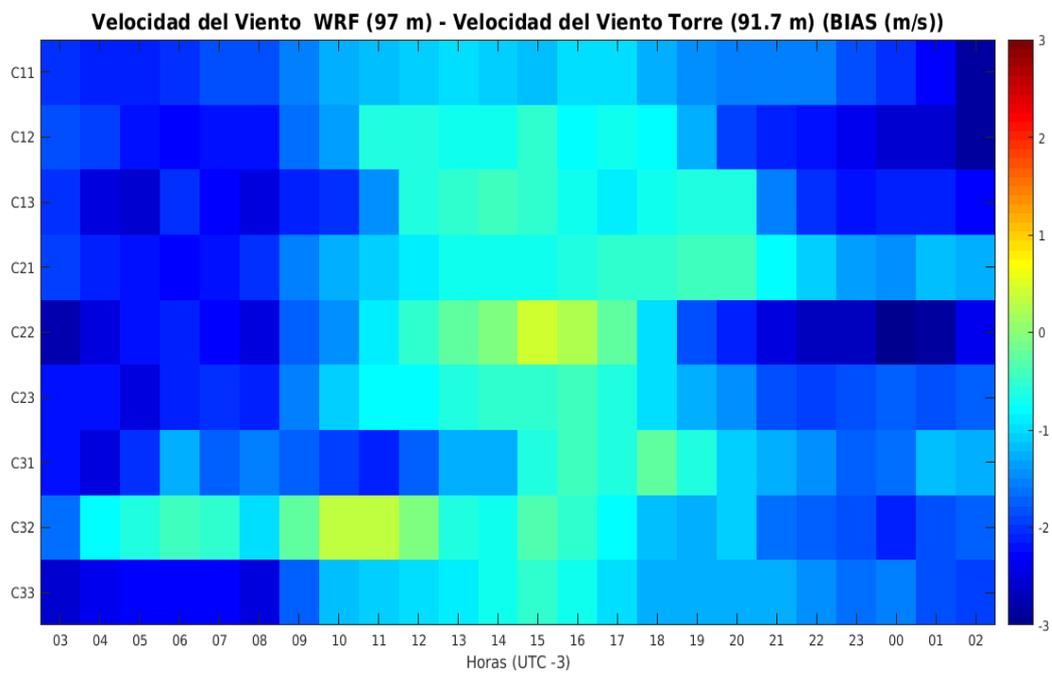


Figura 4.6: Corrección de la velocidad media del viento para la coordenada geográfica de la Torre de Medición Valentines, para los nueve umbrales elegidos modelo WRF-ARW con la parametrización de capa límite atmosférica Yonsei University.

Apéndice 5

Modelos de Pronóstico

5.1. Modelos Basados en Regresión Lineal

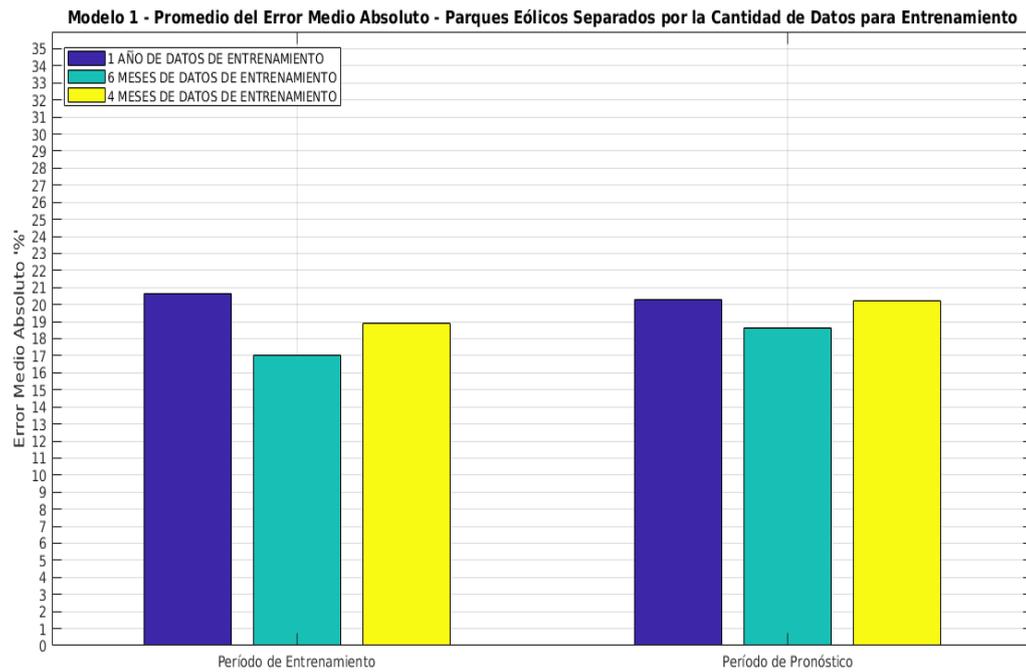


Figura 5.1: Promedio del error medio absoluto de pronóstico del modelo 1, para parques eólicos divididos por cantidad de datos de entrenamiento.

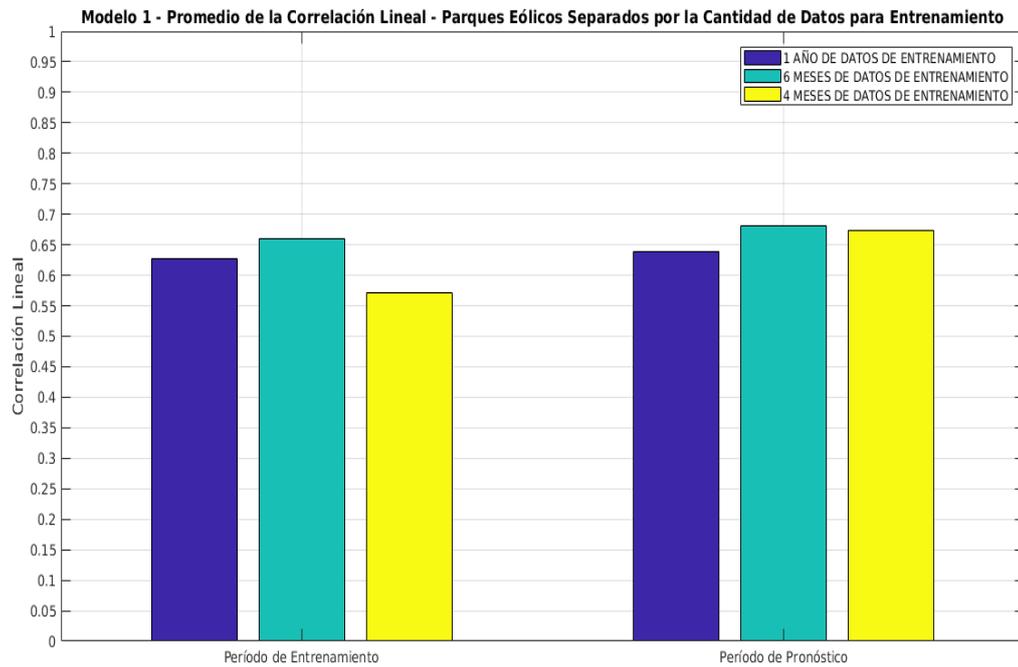


Figura 5.2: Promedio de la correlación lineal de pronóstico del modelo 1, para parques eólicos divididos por cantidad de datos de entrenamiento.

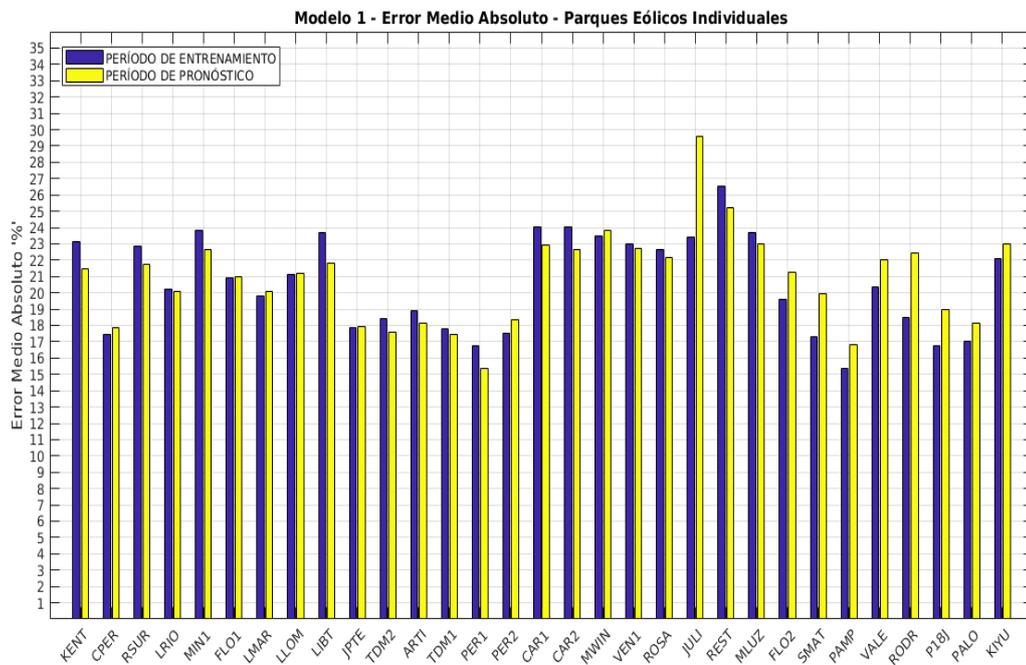


Figura 5.3: Error medio absoluto de pronóstico del modelo 1, para parques eólicos individuales.

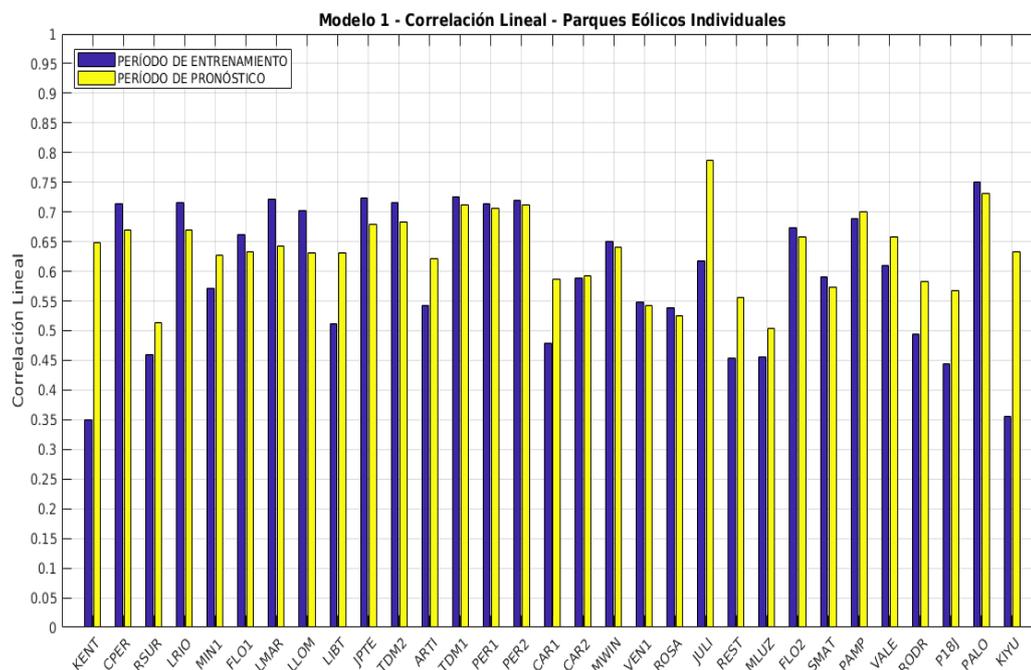


Figura 5.4: Correlación lineal de pronóstico del modelo 1, para parques eólicos individuales.

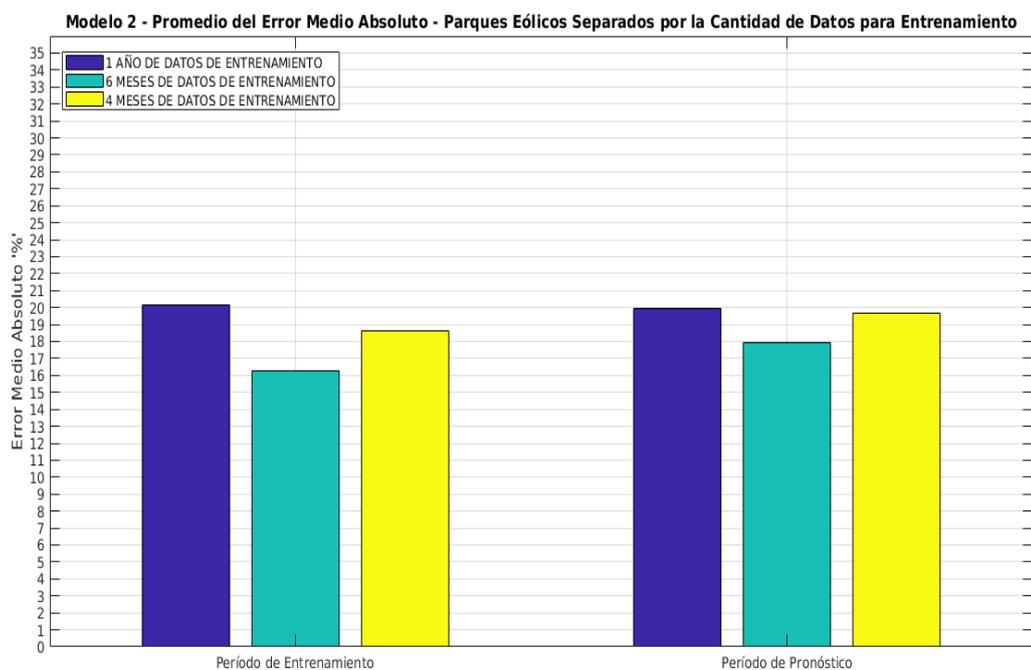


Figura 5.5: Promedio del error medio absoluto de pronóstico del modelo 2, para parques eólicos divididos por cantidad de datos de entrenamiento.

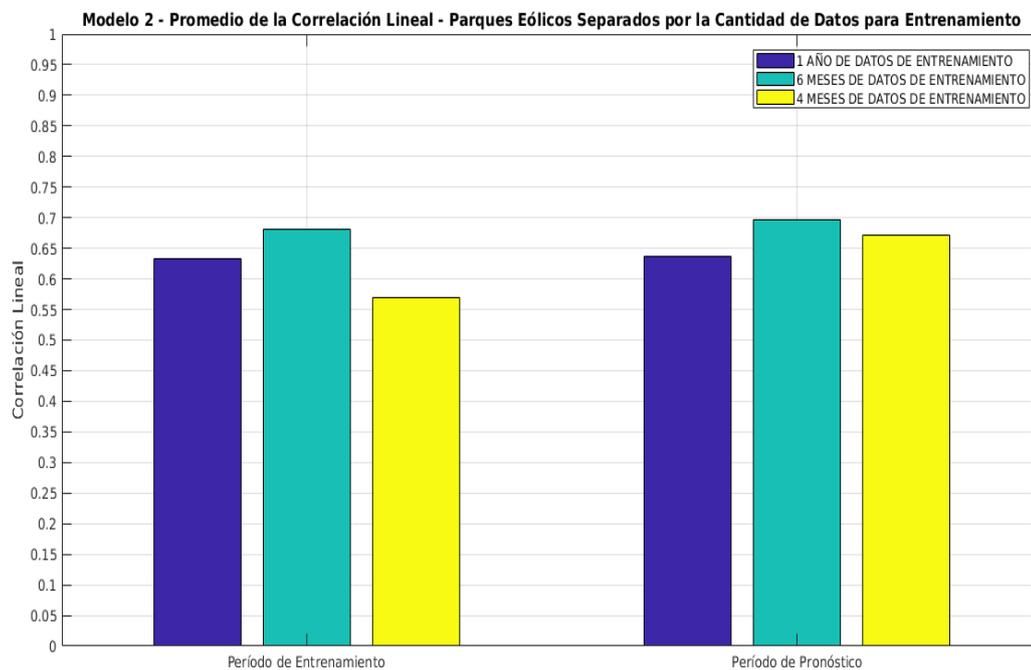


Figura 5.6: Promedio de la correlación lineal de pronóstico del modelo 2, para parques eólicos divididos por cantidad de datos de entrenamiento.

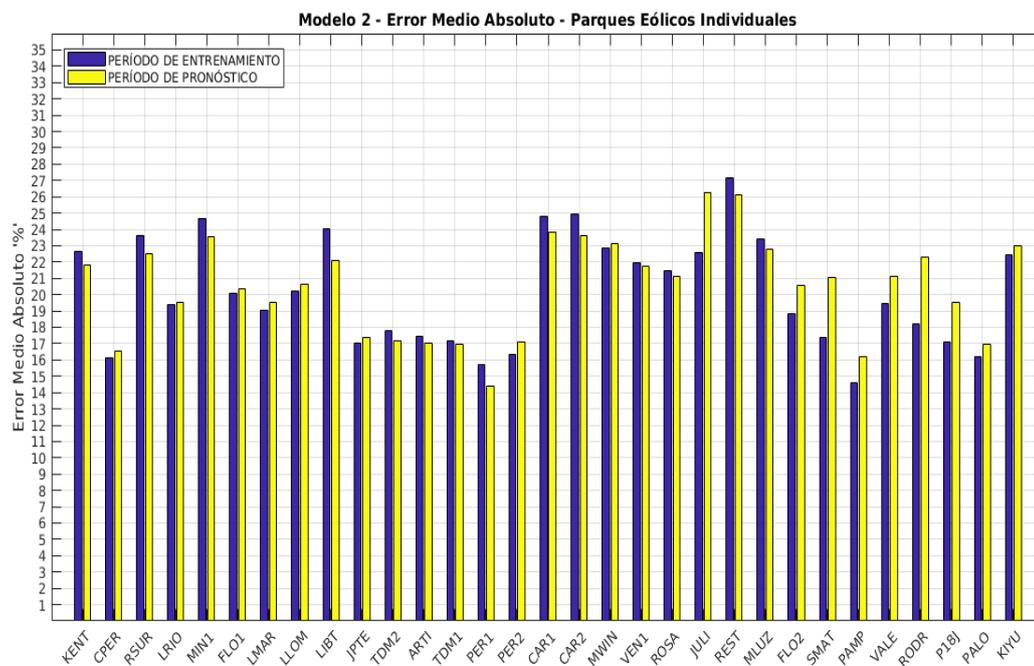


Figura 5.7: Error medio absoluto de pronóstico del modelo 2, para parques eólicos individuales.

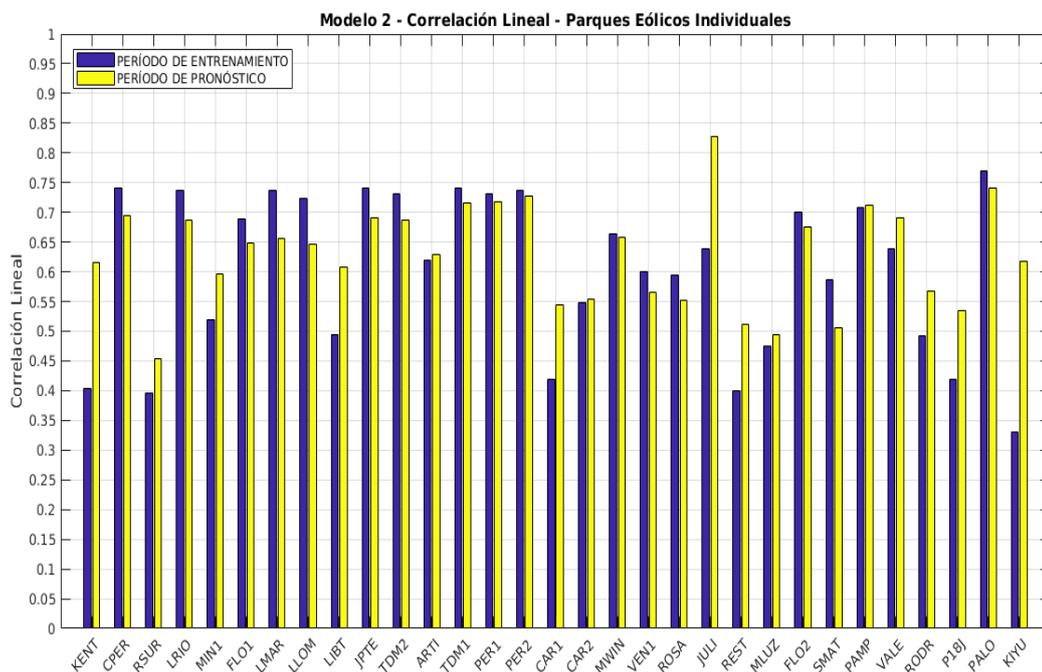


Figura 5.8: Correlación lineal de pronóstico del modelo 2, para parques eólicos individuales.

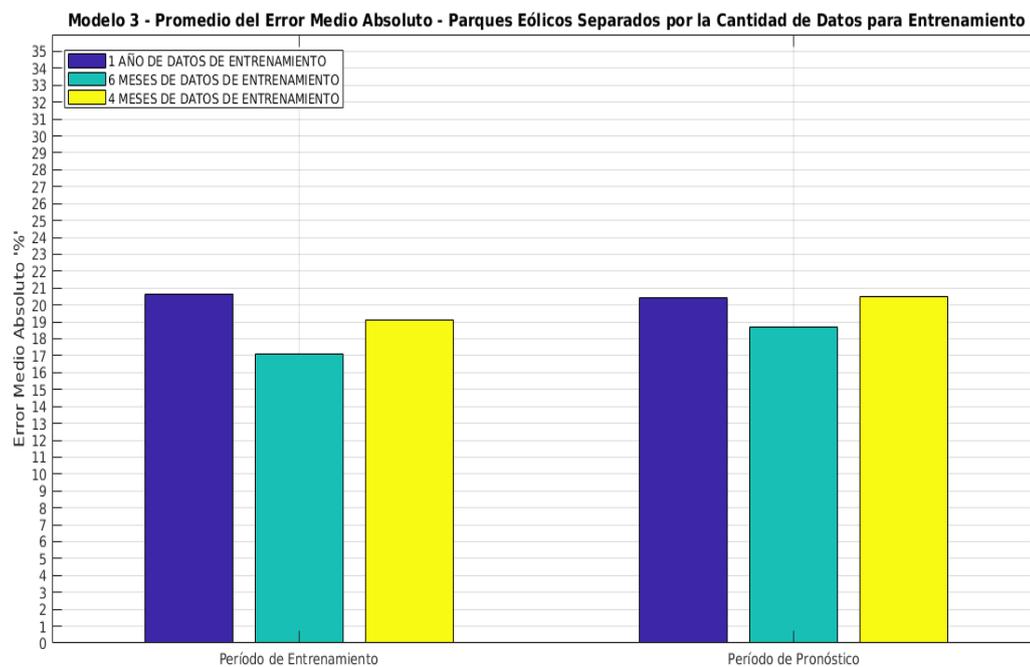


Figura 5.9: Promedio del error medio absoluto de pronóstico del modelo 3, para parques eólicos divididos por cantidad de datos de entrenamiento.

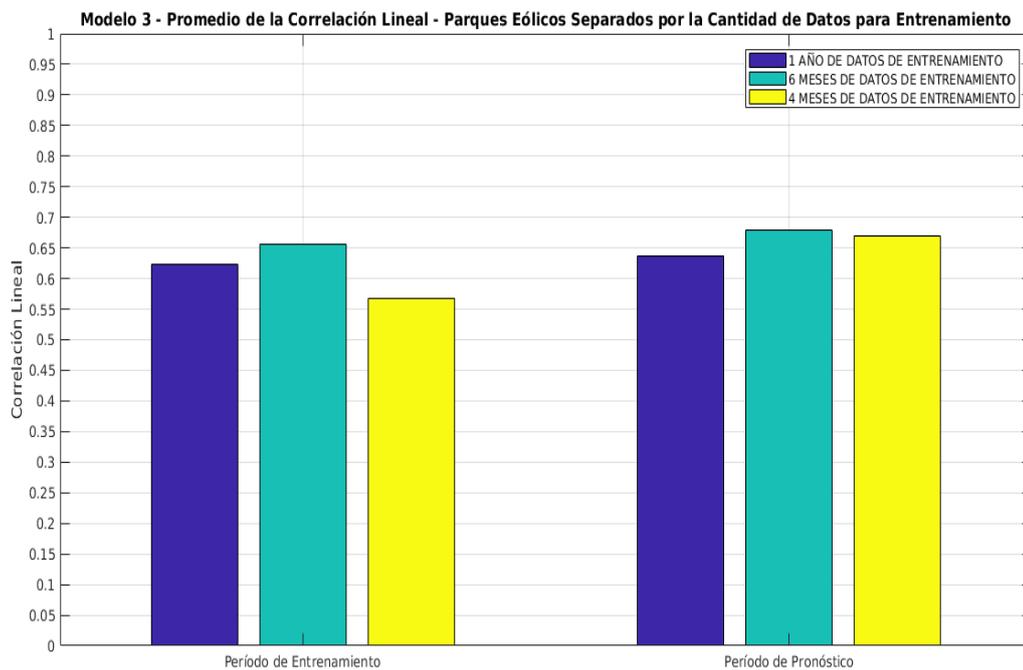


Figura 5.10: Promedio de la correlación lineal de pronóstico del modelo 3, para parques eólicos divididos por cantidad de datos de entrenamiento.

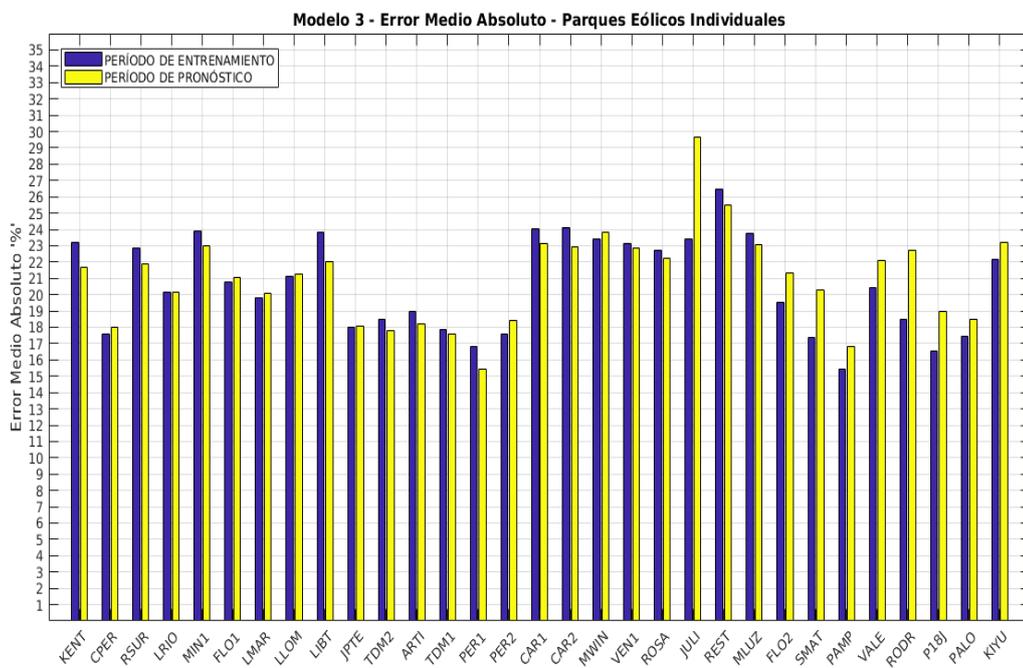


Figura 5.11: Error medio absoluto de pronóstico del modelo 3, para parques eólicos individuales.

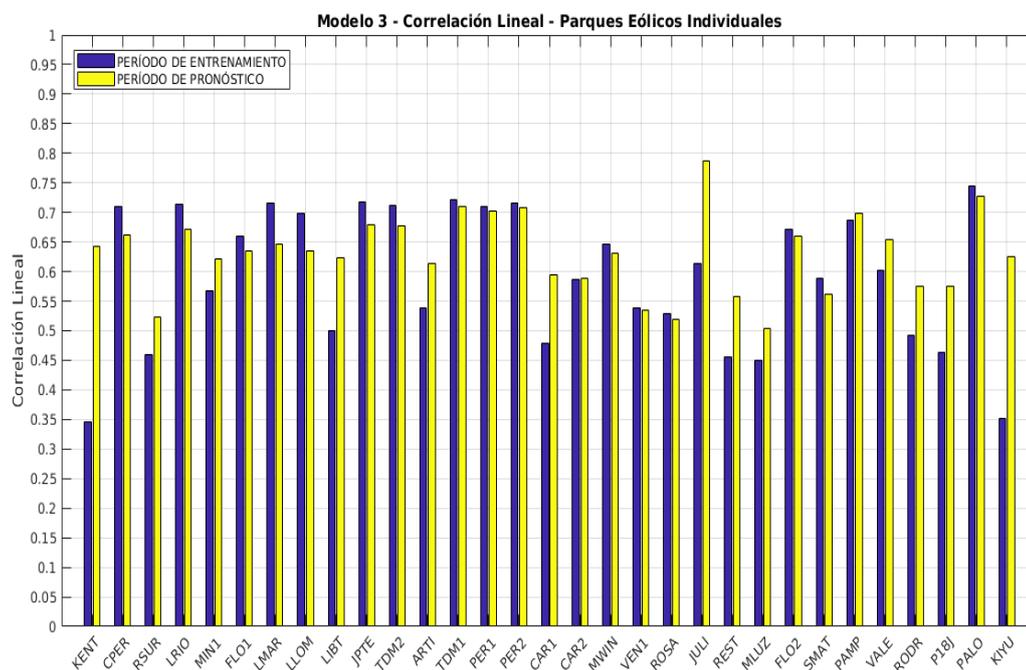


Figura 5.12: Correlación lineal de pronóstico del modelo 3, para parques eólicos individuales.

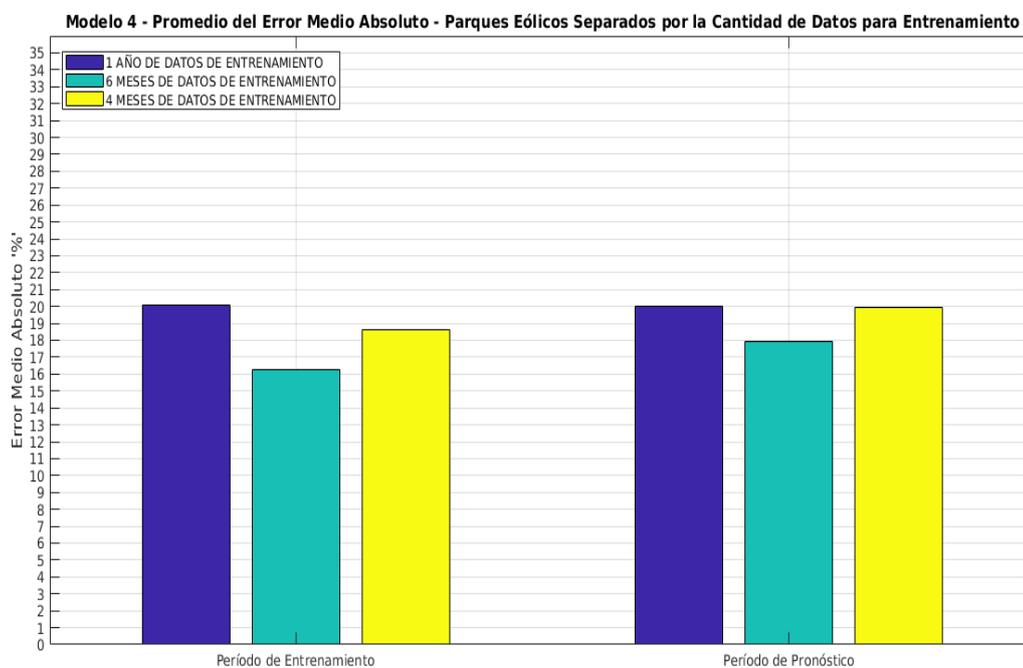


Figura 5.13: Promedio del error medio absoluto de pronóstico del modelo 4, para parques eólicos divididos por cantidad de datos de entrenamiento.

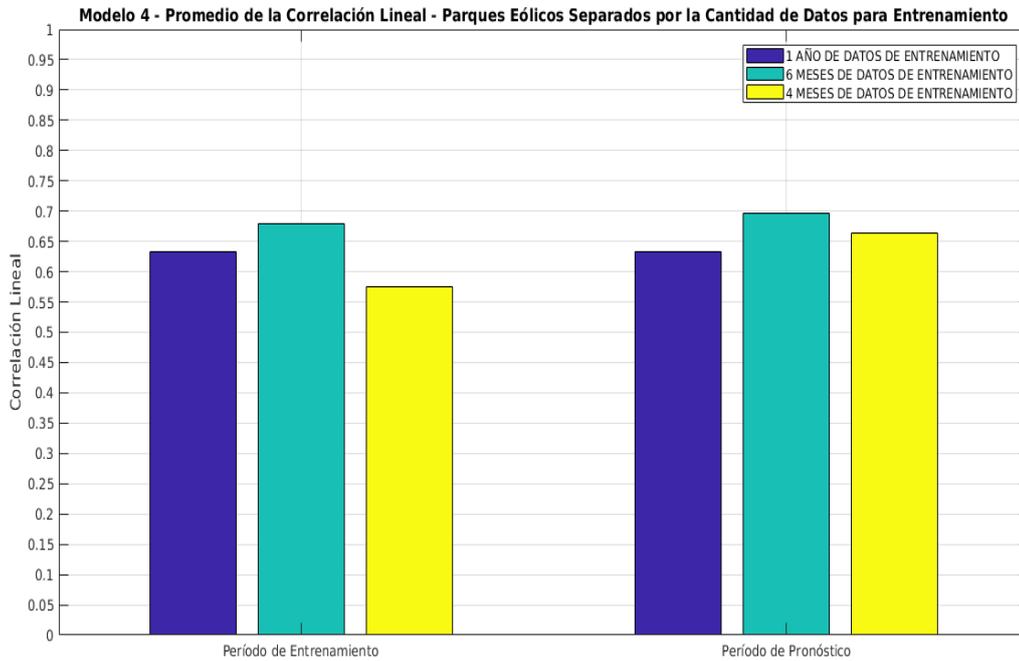


Figura 5.14: Promedio de la correlación lineal de pronóstico del modelo 4, para parques eólicos divididos por cantidad de datos de entrenamiento.

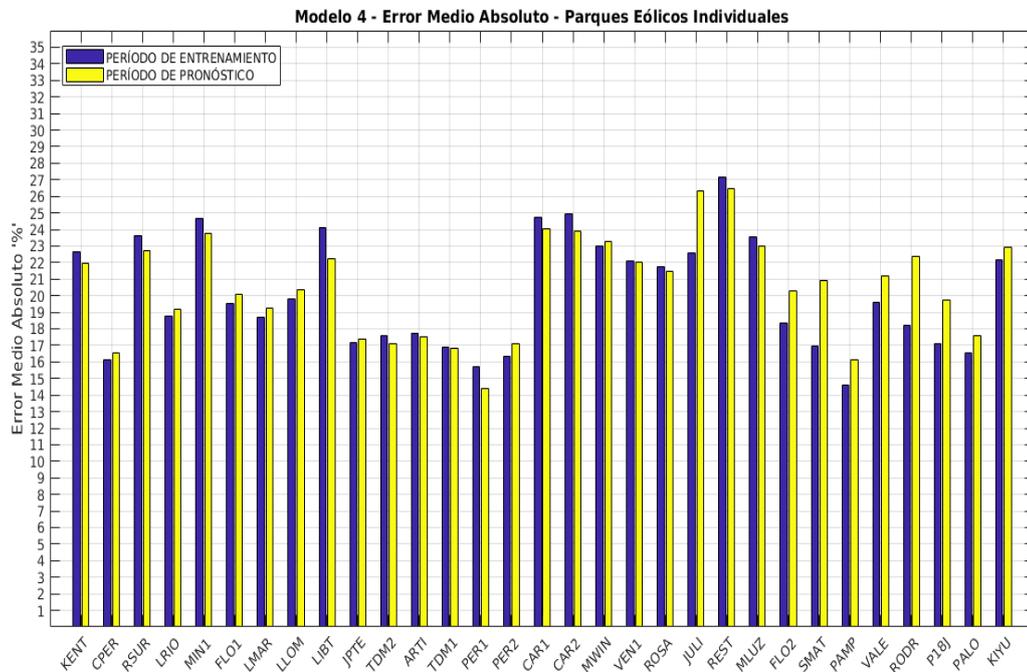


Figura 5.15: Error medio absoluto de pronóstico del modelo 4, para parques eólicos individuales.

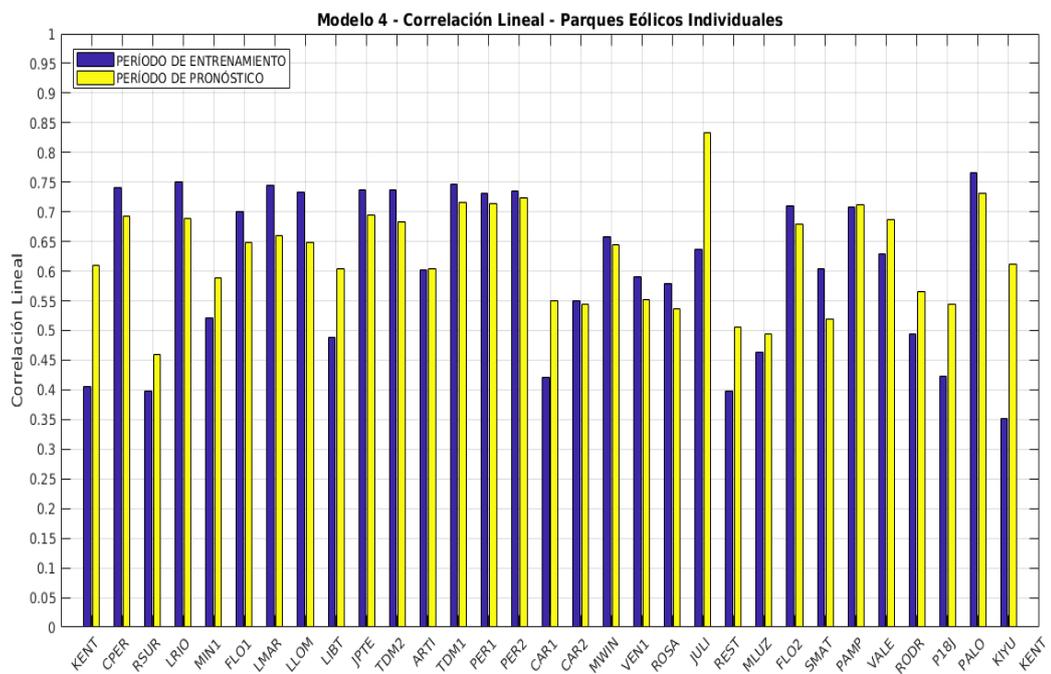


Figura 5.16: Correlación lineal de pronóstico del modelo 4, para parques eólicos individuales.

Apéndice 6

Modelos de Pronóstico

6.1. Modelos Basados en Redes Neuronales Artificiales

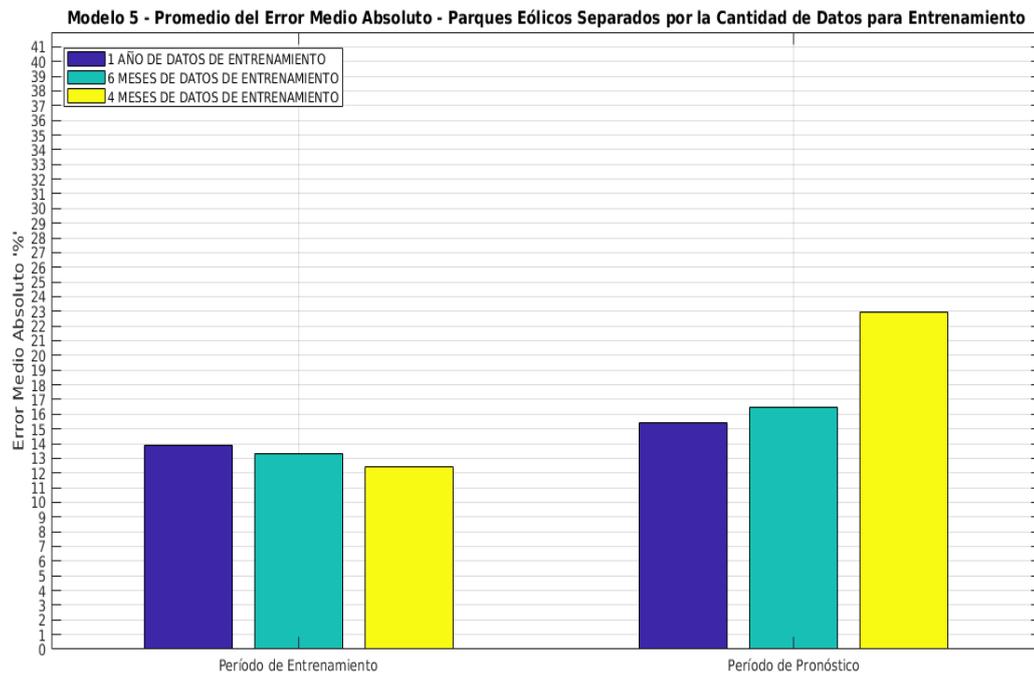


Figura 6.1: Promedio del error medio absoluto de pronóstico del modelo 5, para parques eólicos divididos por cantidad de datos de entrenamiento.

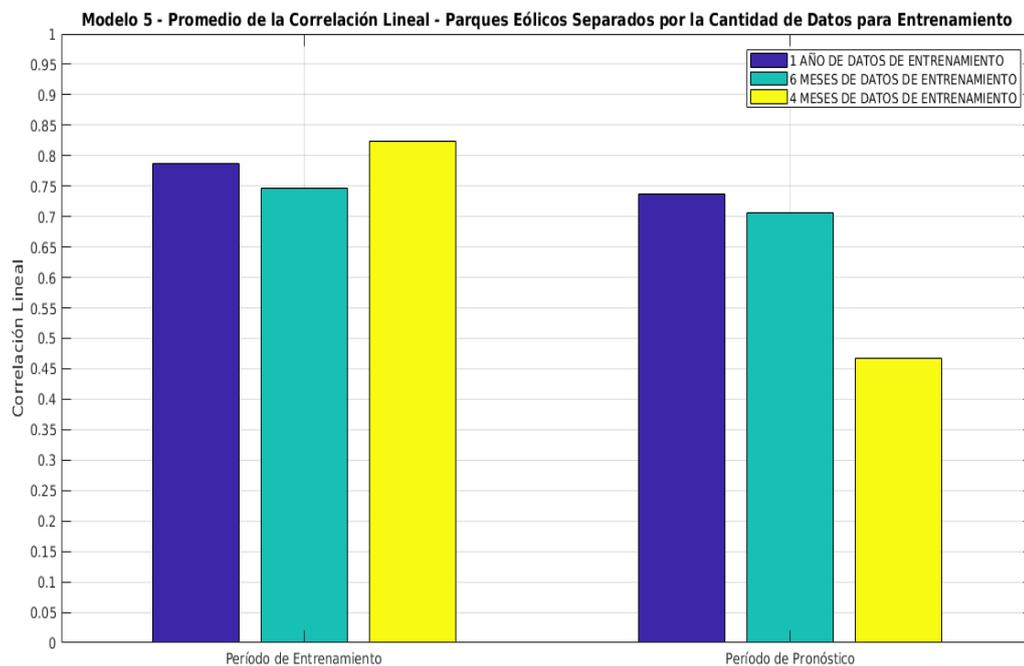


Figura 6.2: Promedio de la correlación lineal de pronóstico del modelo 5, para parques eólicos divididos por cantidad de datos de entrenamiento.

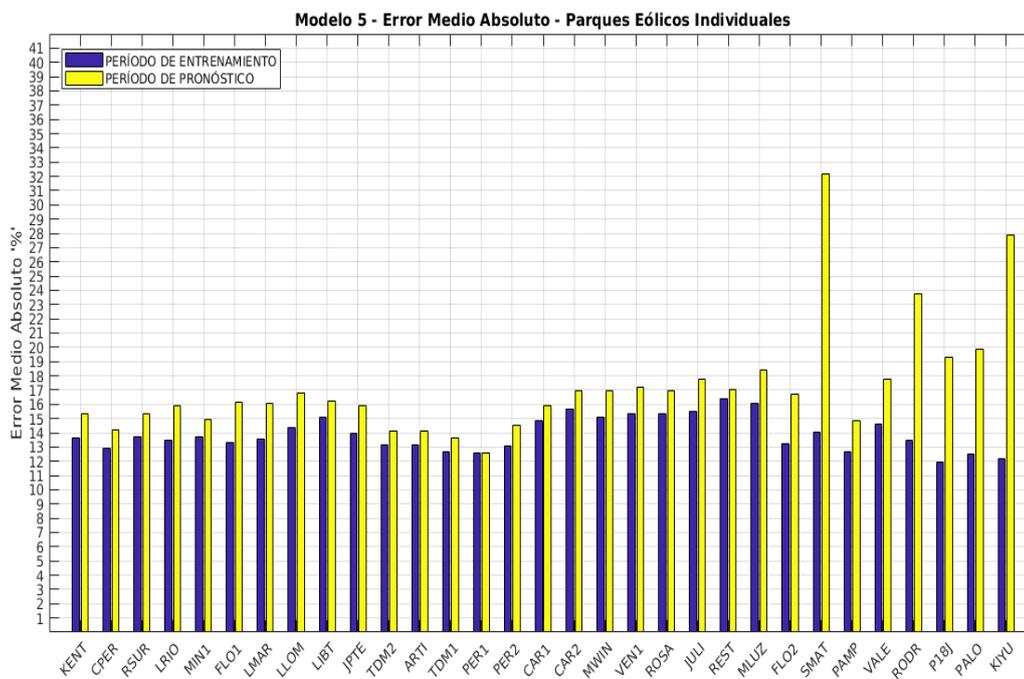


Figura 6.3: Error medio absoluto de pronóstico del modelo 5, para parques eólicos individuales.

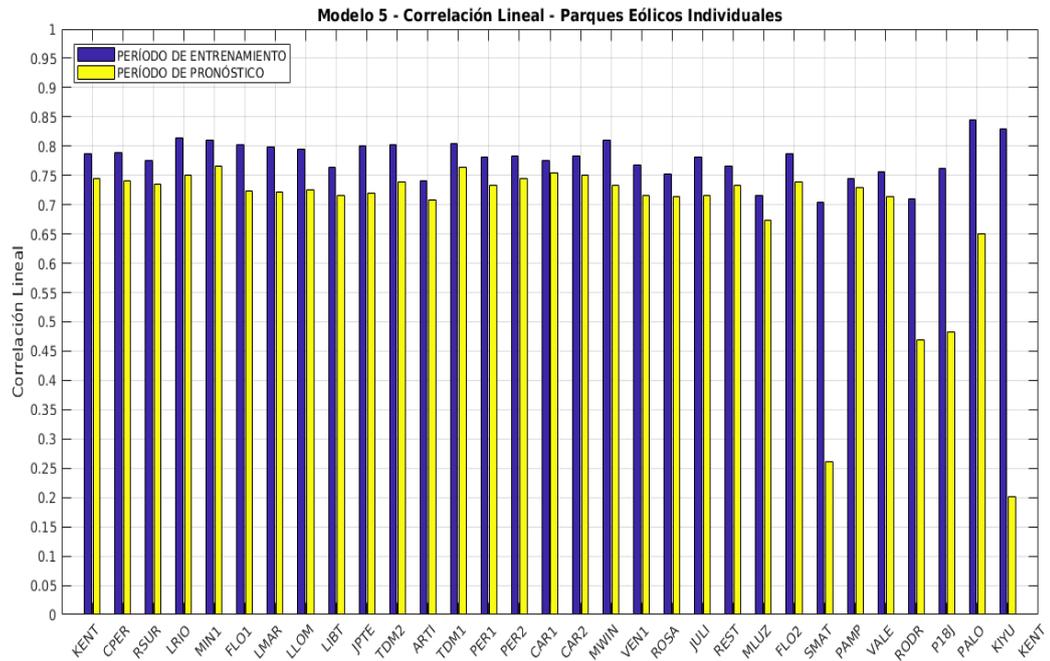


Figura 6.4: Correlación lineal de pronóstico del modelo 5, para parques eólicos individuales.

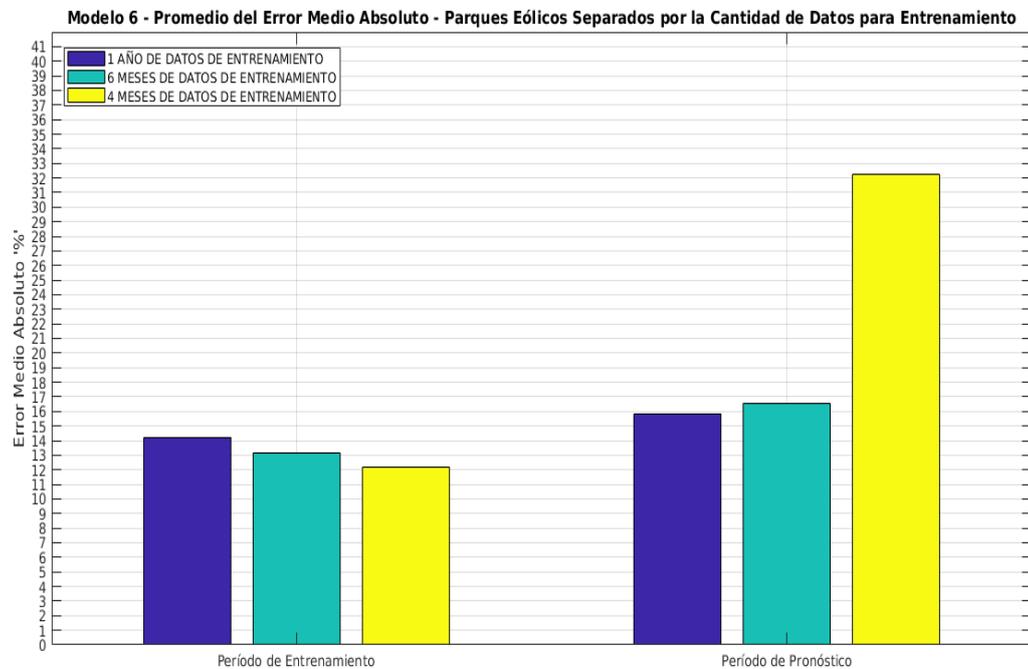


Figura 6.5: Promedio del error medio absoluto de pronóstico del modelo 6, para parques eólicos divididos por cantidad de datos de entrenamiento.

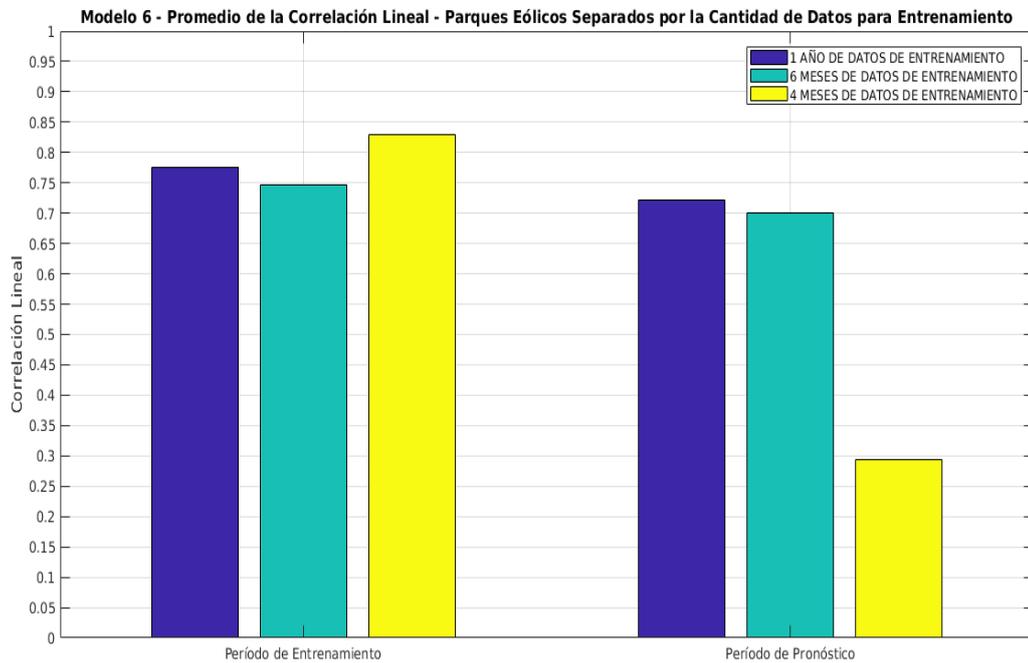


Figura 6.6: Promedio de la correlación lineal de pronóstico del modelo 6, para parques eólicos divididos por cantidad de datos de entrenamiento.

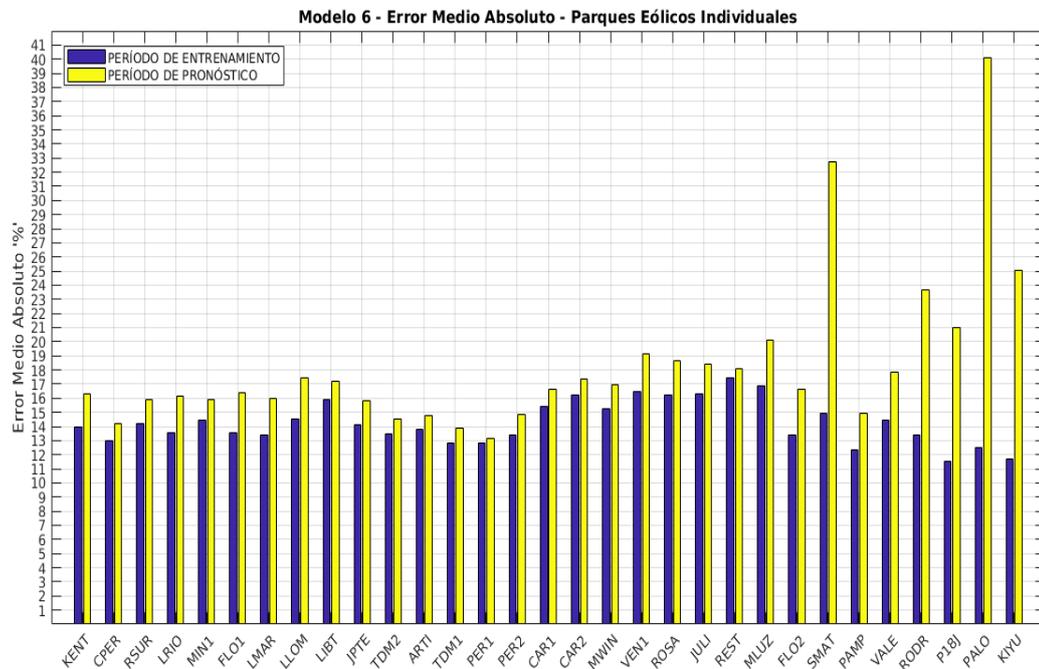


Figura 6.7: Error medio absoluto de pronóstico del modelo 6, para parques eólicos individuales.

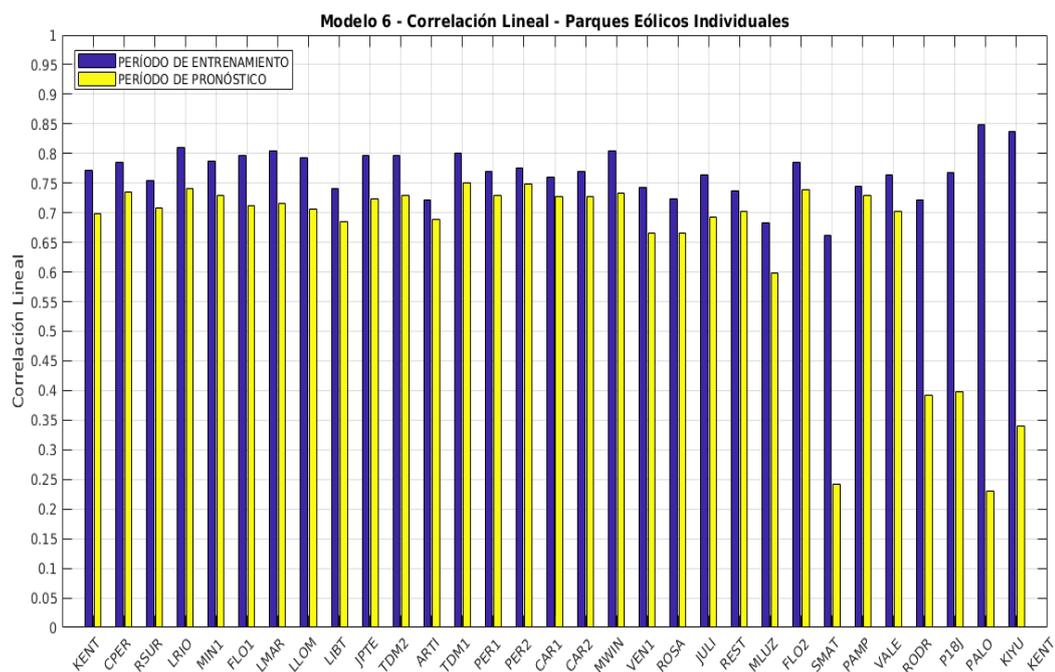


Figura 6.8: Correlación lineal de pronóstico del modelo 6, para parques eólicos individuales.

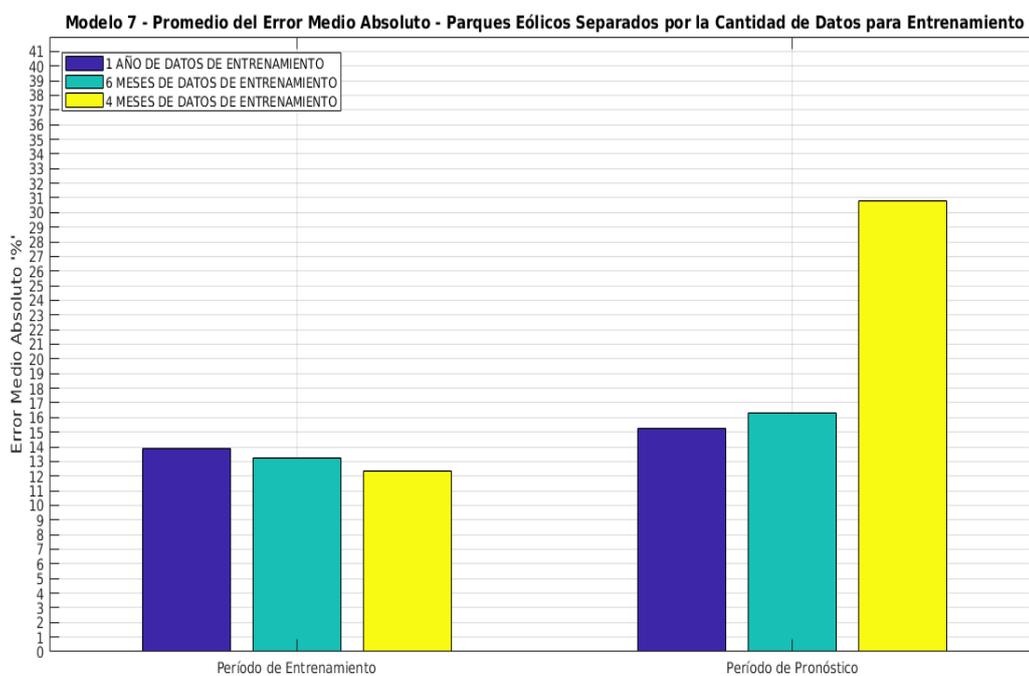


Figura 6.9: Promedio del error medio absoluto de pronóstico del modelo 7, para parques eólicos divididos por cantidad de datos de entrenamiento.

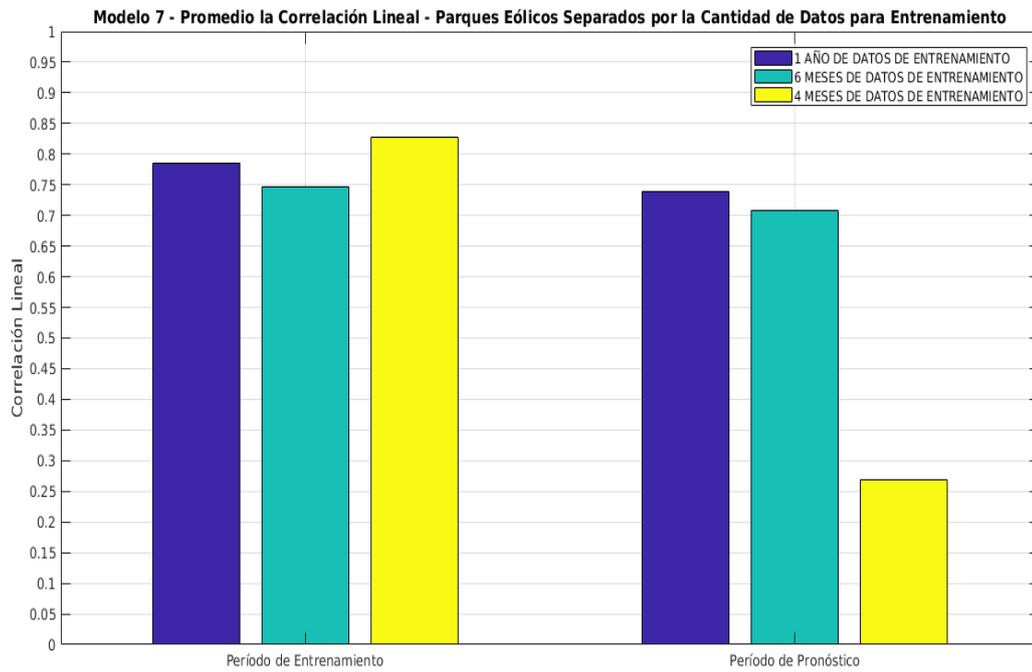


Figura 6.10: Promedio de la correlación lineal de pronóstico del modelo 7, para parques eólicos divididos por cantidad de datos de entrenamiento.

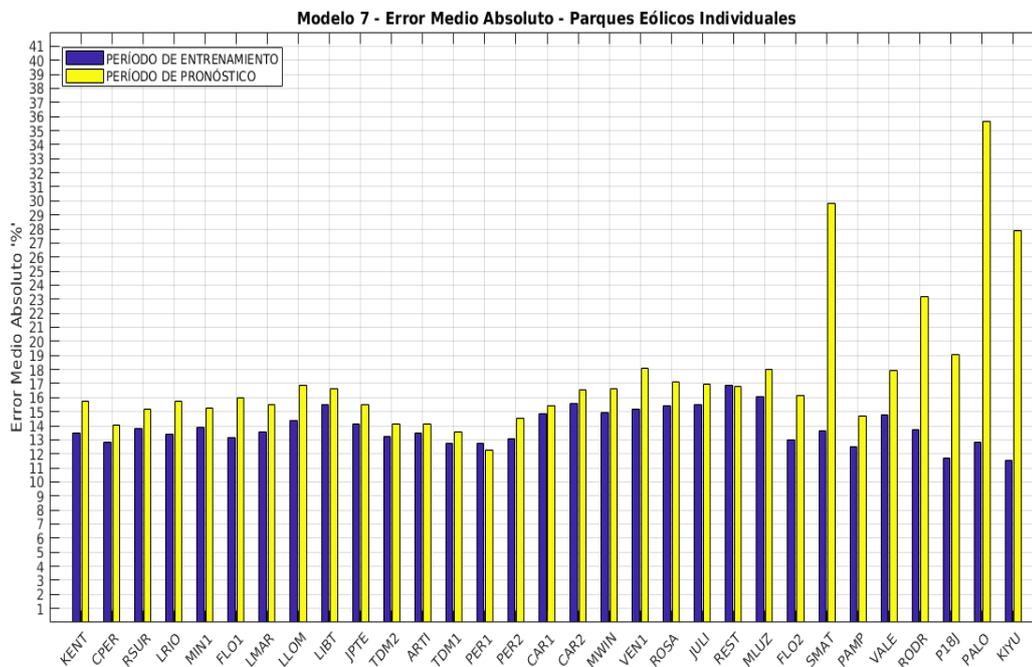


Figura 6.11: Error medio absoluto de pronóstico del modelo 7, para parques eólicos individuales.

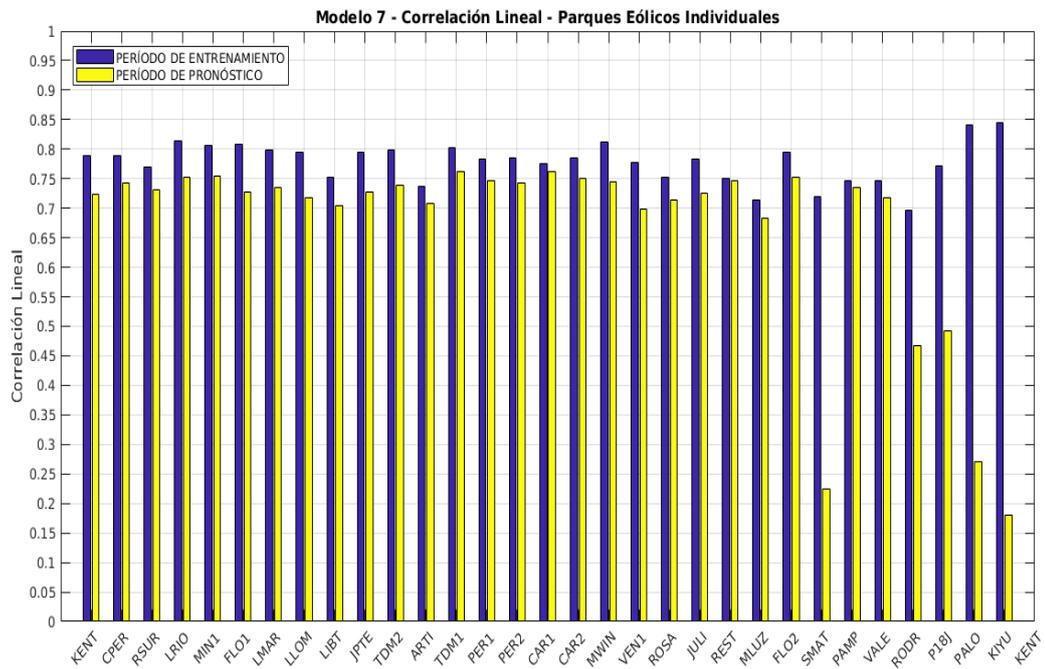


Figura 6.12: Correlación lineal de pronóstico del modelo 7, para parques eólicos individuales.

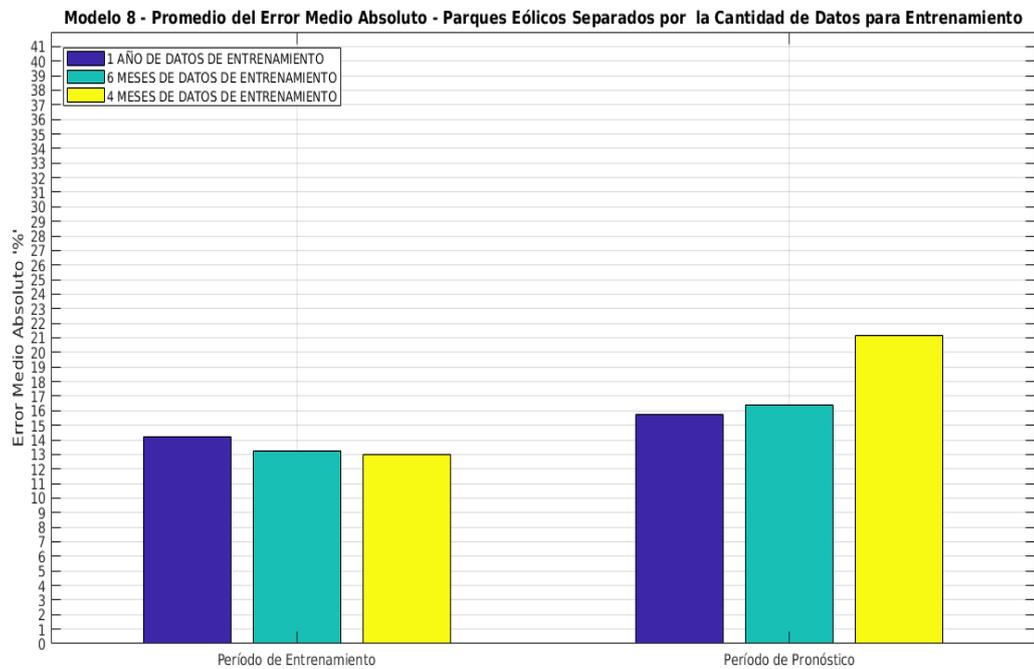


Figura 6.13: Promedio del error medio absoluto de pronóstico del modelo 8, para parques eólicos divididos por cantidad de datos de entrenamiento.

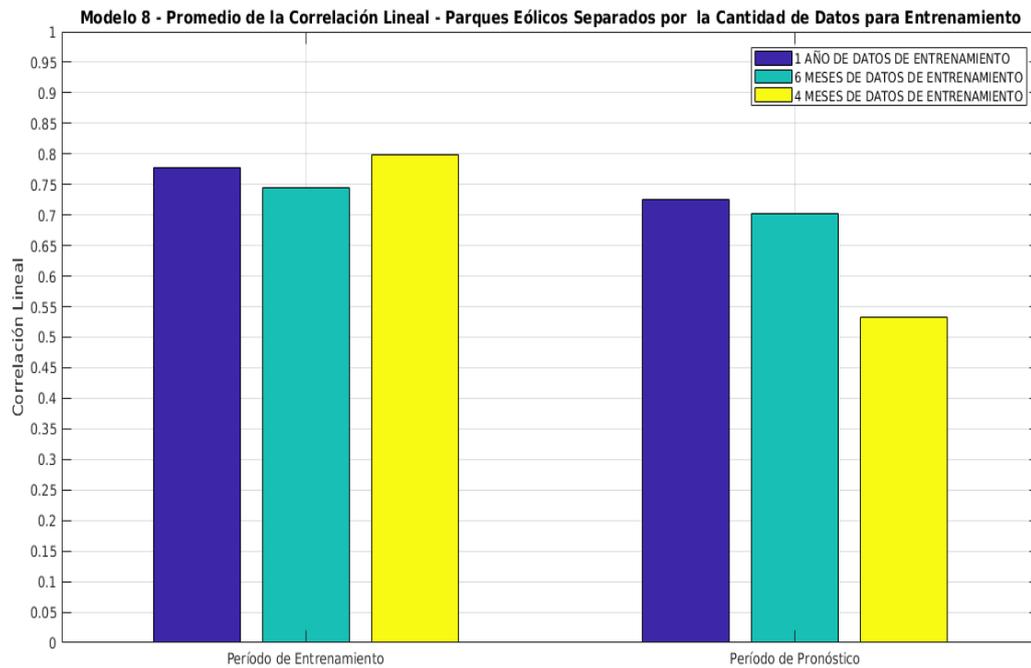


Figura 6.14: Promedio de la correlación lineal de pronóstico del modelo 8, para parques eólicos divididos por cantidad de datos de entrenamiento.

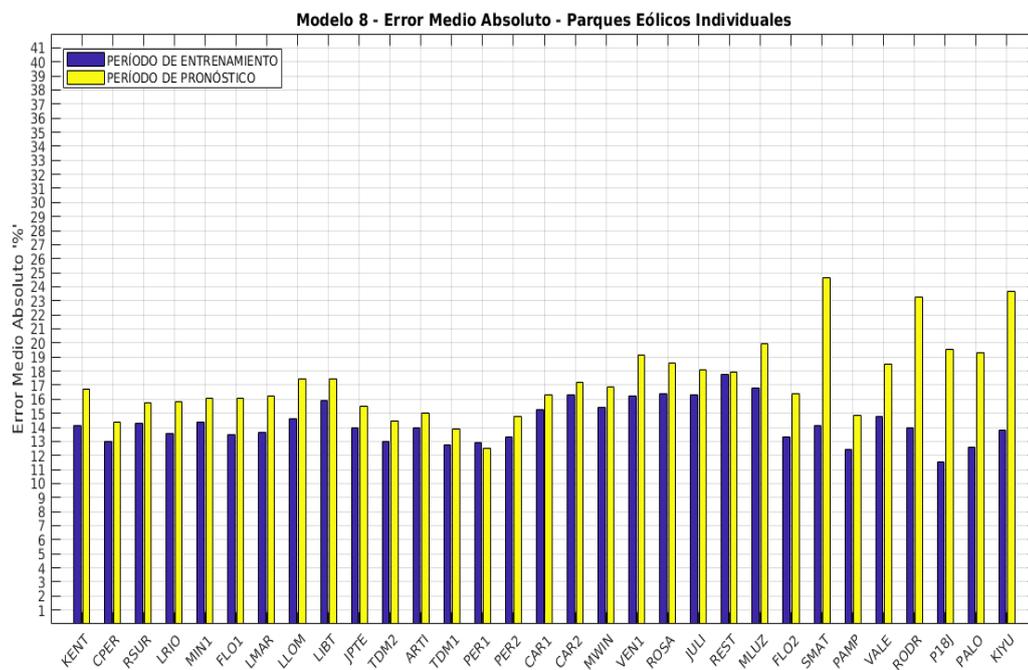


Figura 6.15: Error medio absoluto de pronóstico del modelo 8, para parques eólicos individuales.

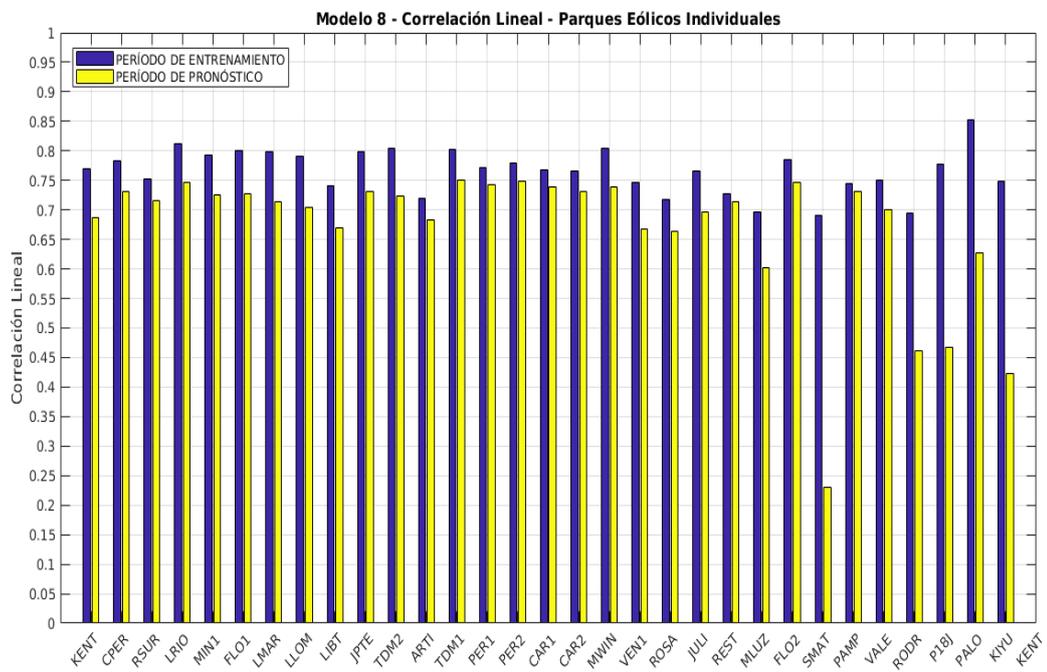


Figura 6.16: Correlación lineal de pronóstico del modelo 8, para parques eólicos individuales.