

enerLAC

Revista de
Energía de
Latinoamérica
y el Caribe

Generación
de energía
en PTAR

Pronóstico
energía eólica
en Uruguay

Simulación
sistema
fotovoltaico
en Haití

Operación
óptima de
baterías

Transición
sistemas de
energía eléctrica

Pronósticos
hidrológicos y
el sistema eléctrico

Modelo numérico
de la combustión de
tronco cilíndrico



© Copyright Organización Latinoamericana de Energía (OLADE) 2019. Todos los derechos reservados.

ISSN: 2602-8042 (Impresa)

ISSN: 2631-2522 (Electrónica)

Dirección: Av. Mariscal Antonio José de Sucre N58-63 y
Fernández Salvador.
Quito - Ecuador

Página web Revista ENERLAC: <http://enerlac.olade.org>

Página web OLADE: www.olade.org

Mail ENERLAC: enerlac@olade.org

Teléfonos: (+593 2) 2598-122 / 2598-280 / 2597-995



COMITÉ EDITORIAL

Alfonso Blanco
SECRETARIO EJECUTIVO DE OLADE

Pablo Garcés
ASESOR TÉCNICO DE OLADE

Marcelo Vega
COORDINADOR DE LA COMISIÓN ACADÉMICA DE LA
ASOCIACIÓN DE UNIVERSIDADES GRUPO MONTEVIDEO
(AUGM)

COMITÉ AD-HONOREM

Andrés Romero C.
Pontificia Universidad Católica de Chile.

Leonardo Beltrán.
Institute of the Americas. México.

Manlio Coviello.
Pontificia Universidad Católica de Chile.

Mauricio Medinaceli.
Investigador independiente. Bolivia.

Ubiratan Francisco Castellano.
Investigador independiente. Brasil.

COORDINADORES DE LA EDICIÓN

DIRECTOR GENERAL
Alfonso Blanco

DIRECTORES EJECUTIVOS
Pablo Garcés
Marcelo Vega

COORDINADORA DE PRODUCCIÓN
Blanca Guanocunga. Bibliotecaria OLADE

COLABORADORES

Raquel Atiaja. *Técnica de Área Informática OLADE*

Ana María Arroyo. *Diseño y diagramación*

REVISORES

Santiago Garrido. *Universidad Nacional de Quilmes. Instituto de Estudios sobre la Ciencia y la Tecnología. Argentina.*

Emilia Ruggeri. *Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET – IESCT). Universidad Nacional de Quilmes. Argentina.*

Diego Coronel Bejarano. *Universidad Nacional de Asunción. Grupo de Investigación en Sistemas Energéticos (GISE - FPUNA). Paraguay.*

Luciana Clementi. *Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Argentina.*

José Javier Alonso Mateos. *Universidad Internacional de Valencia. España.*

Oscar Oviedo. *Universidad Nacional de Córdoba (UNC - INFIQC). Argentina.*

Alfredo Caguao Yagua. *Universidad Nacional Experimental Francisco de Miranda (UNEFM). Venezuela.*

Byron Chilibingua Mazón. *Consultor independiente. Ecuador.*

Reynaldo Payano Almanzar. *Investigador independiente. Chile.*

Iván López. *Universidad de la República (UdelaR) - FING-IMFIA. Uruguay.*

Cristhian Carrasco Villanueva. *Universidad Mayor de San Andrés (UMSA). Bolivia.*

Ojilve Ramón Medrano Pérez. *Consejo Nacional de Ciencia y Tecnología (CONACYT). Centro del Cambio Global y la Sustentabilidad (CCGS). México.*

Diseño de la portada y contraportada Ana María Arroyo y Francisco Pérez.

NOTA DE RESPONSABILIDAD DE CONTENIDO

Las ideas expresadas en este documento son responsabilidad de los autores y no comprometen a las organizaciones mencionadas.

PRONÓSTICO DE ENERGÍA EÓLICA EN URUGUAY PARA HORIZONTES TEMPORALES DE CORTO PLAZO EN BASE A MODELO NUMÉRICO DE MESOESCALA Y REDES NEURONALES ARTIFICIALES

Everton de Almeida ¹, Alejandro Gutiérrez ², Sandro Camargo ³

Recibido: 15/01/2020 y Aceptado: 18/03/2020
ENERLAC. Volumen IV. Número 1. Junio, 2020 (32-43).





1 Magíster en Ingeniería de la Energía por la Universidad de la República (UdelaR), Uruguay. Docente en la Universidad Tecnológica del Uruguay (UTEC), en la carrera de Ingeniería en Energías Renovables. Trabaja en temas relacionados a pronósticos operativos de energía eólica y herramientas de inteligencia artificial aplicadas al sector eléctrico. Temas de interés: pronósticos operativos aplicados al sistema eléctrico, inteligencia artificial, modelos numéricos de circulación atmosférica. ealmeida@fing.edu.uy

2 Ingeniero Industrial Mecánico, Doctor en Mecánica de los Fluidos Aplicada por la Universidad de la República (UdelaR), Uruguay. Profesor Agregado en régimen de dedicación total de la Facultad de Ingeniería (UdelaR). Temas de interés incluyen: energía eólica; pronóstico energético en base a modelos de mesoescala con aplicación a modelos de ráfagas y otras variables vinculadas con el mantenimiento de aerogeneradores; diseño de máquinas en interacción con fluidos. Experiencia en el desarrollo de pequeños aerogeneradores. En el marco de la crisis del Covid-19 ha participado en el desarrollo de respiradores artificiales. aguti@fing.edu.uy

3 Doctor en Ciencias de la Computación por la Universidade Federal do Rio Grande do Sul (UFRGS). Profesor de tiempo completo en la Universidad Federal de Pampa (UNIPAMPA) en la carrera de Ingeniería de la Computación. Profesor permanente en el Programa de Posgrado en Computación Aplicada (PPGCAP) de la EMBRAPA/UNIPAMPA. Temas de interés incluyen: Inteligencia Artificial, Aprendizaje Automático, Redes Neuronales, Bioinformática y Ganadería de Precisión. sandro.camargo@unipampa.edu.br

RESUMEN

Uruguay tiene el 34.43% de la matriz energética de origen eólico. Dada la característica fluctuante del viento es necesario incorporar modelos de pronóstico de energía eólica, de modo de suministrar información para realizarse el despacho óptimo de energía en el sistema eléctrico. Este trabajo presenta los resultados de ocho modelos de pronóstico desarrollados, siendo cuatro en base a un híbrido de modelo numérico de mesoescala y regresión lineal (WRF-RL) y cuatro en base a modelo numérico de mesoescala y redes neuronales artificiales (WRF-RNA). Los resultados fueron evaluados para un total de 31 parques eólicos ubicados en Uruguay, y el modelo que mostró el mejor desempeño fue un modelo híbrido del tipo WRF-RNA. En un análisis del ciclo diario, considerando un pronóstico con la suma de potencia de todos los parques eólicos, los resultados muestran que los menores valores de sesgo (bias) fueron de 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 %).

Palabras clave: Energías Renovables, Inteligencia Artificial, Modelos de Pronóstico, Despacho Económico, Integración en el Sistema Eléctrico, Uruguay.

ABSTRACT

In Uruguay, 34.43 percent of the energy matrix comes from wind energy. Given the wind's fluctuating characteristics it is a necessity to incorporate wind energy prediction models in order to give the proper information to achieve an optimal energy dispatch in the electrical system. This paper presents the results of the eight prediction models developed, with four being based on an hybrid of the mesoscale numeric model and linear regression (WRF-RL) and four based on the mesoscale numeric model and artificial neural networks (WRF-RNA). The

results were evaluated for a total of 31 wind farms located in Uruguay, and the model that showed the best performance was the WRF-RNA one. When analyzing a daily cycle, considering a forecast with the power of all wind farms combined, the results show that the WRF-RNA models had not only the lowest bias value, but the lowest mean absolute error (between 10 and 6.5 percent) when compared to the WRF-RL models (between 14 and 9 percent).

Keywords: Renewable Energy, Artificial Intelligence, Forecasting Models, Economic Dispatch, Integrated Power System, Uruguay.



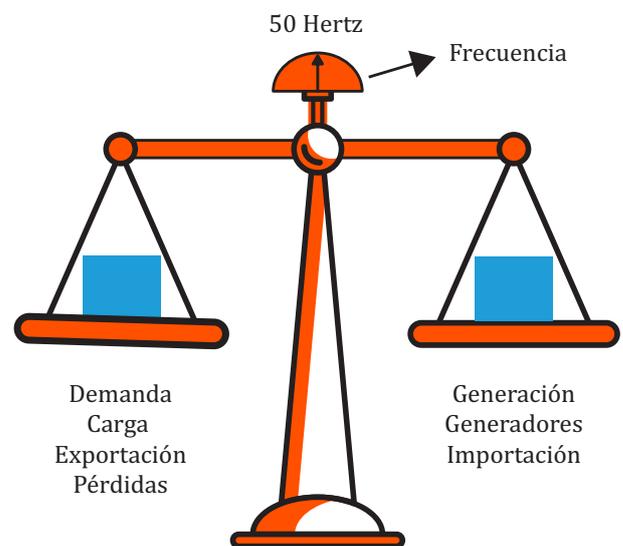
INTRODUCCIÓN

En la búsqueda por optimizar los costos de generación de energía, lograr una mayor soberanía energética, económica y política y además disminuir las emisiones de gases de efecto invernadero, es que actualmente muchos países buscan la implementación de las energías renovables en sus matrices energéticas. Por su alta implementación, entre las energías de origen renovable, se destaca a nivel mundial la energía eólica. Uruguay es reconocido como un caso de éxito en la implementación de las energías renovables a nivel regional, la cual se hizo en base a una política energética, (MIEM-DNE, 2008), que permitió reducir los riesgos de seguridad energética a nivel nacional, pasando el país de ser netamente importador de energía eléctrica a un exportador a los países vecinos (ADME, 2018). Actualmente, el 34.43% de la potencia instalada en la matriz energética de Uruguay es proveniente de la energía eólica (UTE, 2019). El alto incremento de la participación de la energía eólica en los sistemas eléctricos introdujo nuevos desafíos en la gestión de los sistemas debido a la característica fluctuante a escalas horarias del recurso eólico (Ackermann, T., 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) y balance entre demanda y generación de energía eléctrica (Ackermann, T., 2005).

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 (Gutiérrez, A., 2011). Una herramienta de pronóstico permite respaldar la gestión y planificación óptima de todo un sistema eléctrico con alto incremento de eólica. 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, X., *et. al.*, 2011). La figura 1 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 1: Representación de los desafíos del despacho de energía eléctrica.



Fuente: Adaptado de (UTE-DPE, 2013) y (ONS, 2018).

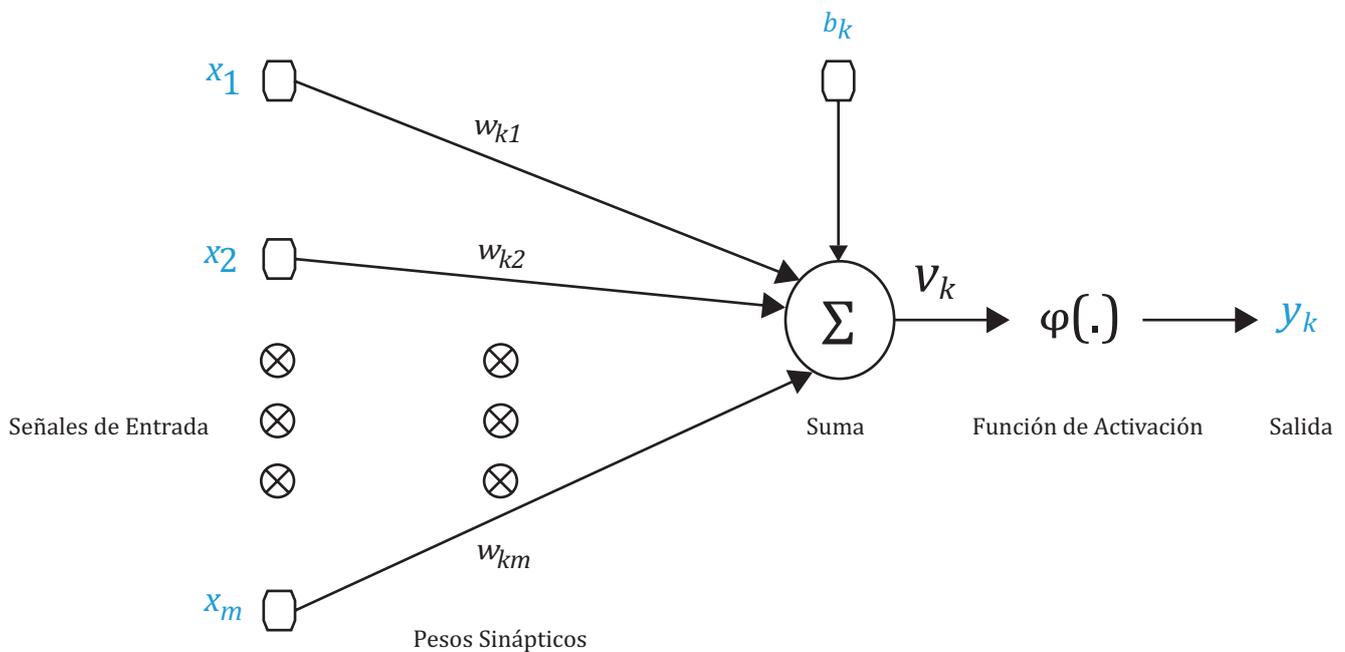
Pronosticar la generación de un parque eólico implica hacer la previsión de las variables atmosféricas que influyen en la generación de energía eólica, como la velocidad del viento y la densidad del aire en la altura del buje de los aerogeneradores (Soman, S., 2015), entre otras que puedan tener influencia, como la dirección del viento, por ejemplo. Los pronósticos del viento se dividen en dos tipos: método físico y el método estadístico (Soman, S., 2015). 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 éste el período 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 y los de redes neuronales

artificiales. A diferencia de los métodos estadísticos de series temporales que son modelos lineales, las redes neuronales artificiales (RNA) resuelven problemas de naturaleza no lineal (Haykin, S., 2009), como por ejemplo, los pronósticos de energía eólica (Soman, *et. al.*, 2010). Las RNA son modelos matemáticos con estructura similar a la del cerebro humano, no lineales, que trabajan en paralelo con múltiples conexiones, teniendo como elemento central las neuronas (Haykin, S., 2009).

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 éstas vectores que contienen valores de variables de entrada, 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, S., 2009). La figura 2 presenta un modelo de neurona “k”, no lineal.

Figura 2. Modelo de neurona “k”, no lineal.



Fuente: Adaptado (Haykin, S., 2009).

Las RNA's se han utilizado principalmente para horizontes de muy corto plazo en la generación de potencia de parques eólicos (Varanasi, J., Tripathi, M.M., 2016) y velocidades de viento (Ozgonenel, O., Thomas, D., 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. En la configuración de estos modelos híbridos, se usan las salidas de los modelos

físicos como variables de entrada en los modelos de RNA. 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, M., Focken, U., 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, R., 2013). Entre los modelos de mesoescala se destaca el "Weather Research and Forecasting" (WRF), (Skamarock, W. et al., 2008) siendo este un modelo de *software* libre de código abierto, tiene el respaldo de la comunidad científica internacional.

METODOLOGÍA

Parques Eólicos

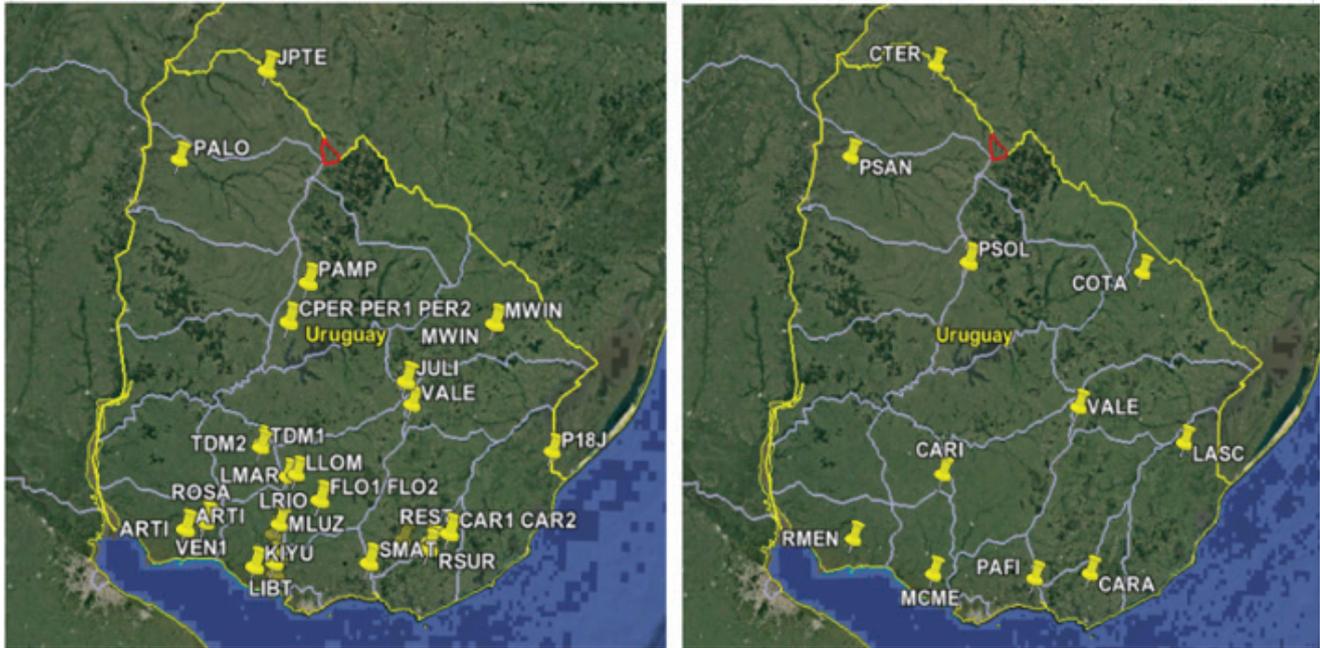
Para el presente trabajo se evalúan ocho modelos de pronóstico desarrollados, los cuales son en base al modelo numérico WRF-ARW + redes neuronales artificiales (WRF-RNA) y WRF-ARW + regresión lineal (WRF-RL). Los modelos de pronósticos desarrollados fueron evaluados para un conjunto de 31 parques eólicos (1267.4 MW) ubicados en territorio Uruguayo, siendo la elección de los 31 parques eólicos en base a un criterio de existencia datos de generación dentro del período de entrenamiento (descrito más adelante). 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 período de entrenamiento para el modelo WRF-RNA, y como período para sacar coeficientes para el modelo WRF-RL. El período 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 período, datos de velocidad media horaria del viento de 11 torres de mediciones, que están ubicadas cerca de los parques eólicos evaluados. Dichos datos fueron utilizados para evaluar si una corrección

de la velocidad del viento del modelo WRF-ARW vía análisis clúster aportaba un mejor pronóstico para los modelos WRF-RNA y WRF-RL. En la base de datos de potencia media horaria, se hizo un pre procesamiento, con la finalidad de filtrar los datos que estaban en condiciones de restricciones operativas (datos de potencia de los parques eólicos) e identificar datos inválidos (por mala medición de los sensores) medidos por las torres. La figura 3 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 clúster.



Figura 3. Parques eólicos (izquierda) y torres de mediciones (derecha) utilizadas para estudio. Los códigos de 4 caracteres están asociados a los nombre de cada parque eólico y torre en estudio. El área en rojo representa un límite contestado entre Uruguay y Brasil, llamado Rincón de Artigas.



Fuente: Elaboración de los autores.

Configuración Modelo WRF-ARW

Fue utilizado para el desarrollo del trabajo 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* 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. La configuración espacial utilizada fue de un dominio centrado en territorio de Uruguay, de resolución de 30 km, con 61 puntos de malla (este-oeste) y

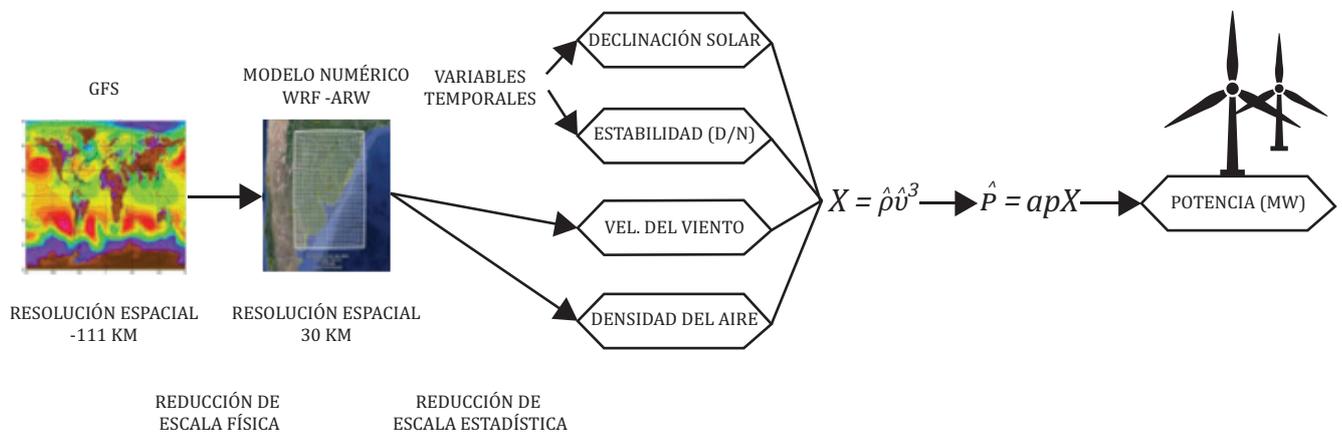
55 puntos de malla (norte-sur). La proyección cartográfica utilizada fue *Lambert Conformal* y los datos con informaciones de topografía y uso del suelo fueron los de USGS. El modelo fue configurado con 30 niveles verticales (por defecto en el modelo). Fueron realizadas simulaciones con dos parametrizaciones físicas de capa límite atmosférica (Mellor-Yamada-Janjic y Yonsei University) y capa de superficie (*Revised MM5* y *Eta Similarity*). Las variables físicas pronosticadas por el modelo WRF-ARW 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.

Configuración de Regresión Lineal

Se plantea un modelo de regresión lineal en el que la potencia pronosticada (P) depende de la densidad (ρ) y la velocidad (v) del viento pronosticada a la altura del eje del aerogenerador por el modelo WRF, siendo “ ap ” el coeficiente calculado por medio de una regresión lineal ($P = apX$, con $X = \rho v^3$). Los coeficientes ap 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, L., 2018). A su vez, el modelo WRF-RL CLÚSTER se le realiza el análisis de sensibilidad en esquemas numéricos de la capa límite y en la corrección de la velocidad por análisis clúster. La figura 4 presenta el esquema de un modelo en base a WRF-RL.

Figura 4. Esquema de modelo WRF-RL utilizado para estudio.



Fuente: Elaboración de los autores.

Fueron desarrollados cuatro modelos en base a regresión lineal (WRF-RL), que tuvieron como configuraciones, las siguientes:

Modelo 1 – Capa límite: Mellor-Yamada-Janjic, capa de la superficie: *Revised MM*, sin corrección de la velocidad del viento por análisis clúster.

Modelo 2 – Capa límite: Mellor-Yamada-Janjic, capa de la superficie: *Revised MM*, con corrección de la velocidad del viento por análisis clúster.

Modelo 3 – Capa límite: *Yonsei University*, capa de la superficie: *Eta Similarity*, sin corrección de la velocidad del viento por análisis clúster.

Modelo 4 – Capa límite: *Yonsei University*, capa de la superficie: *Eta Similarity*, con corrección de la velocidad del viento por análisis clúster.

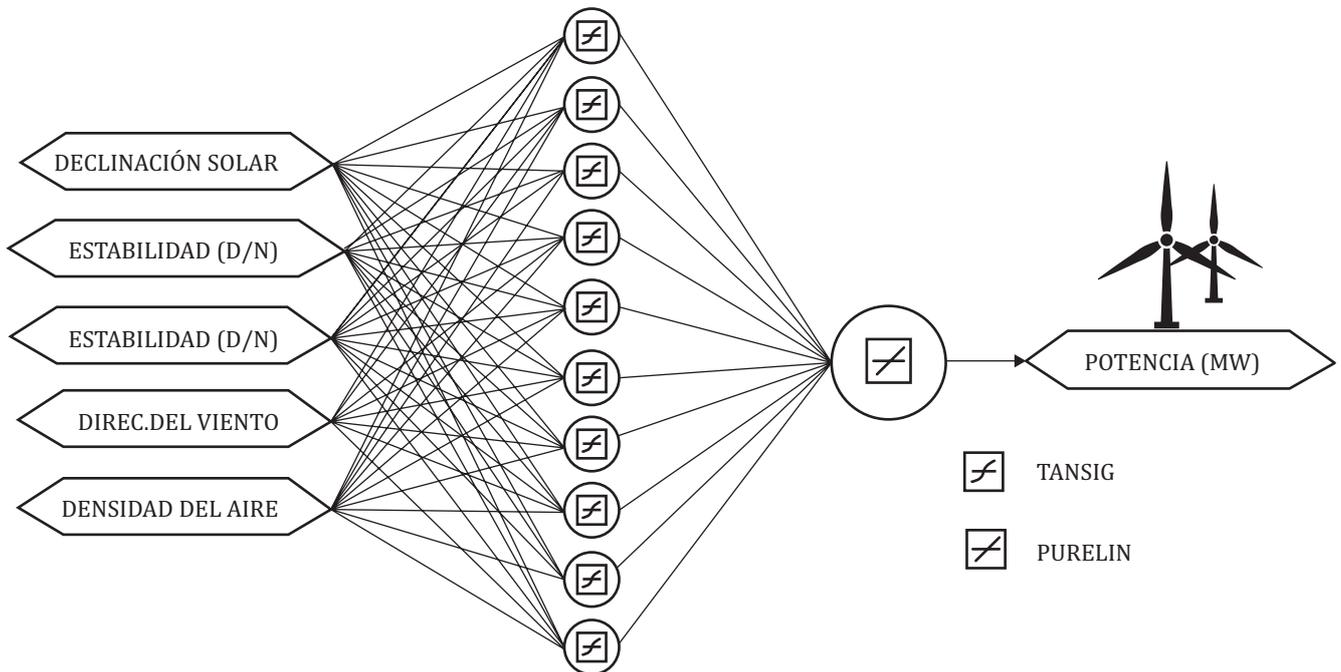
Configuración de Redes Neuronales Artificiales

El modelo WRF-RNA toma como variables de entrada la densidad del aire (ρ), la velocidad del viento (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, T., 2010), asociadas a la estabilidad atmosférica. 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. 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, E. *et al.*, 1986), para el entrenamiento de la red neuronal, donde las variables de entrada del modelo fueron introducidas junto a los datos de potencia para el proceso de aprendizaje, se consideraron datos de potencia media horaria, (variable de pronóstico) 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). 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, D., 1963), la función de aprendizaje fue *Gradient descent with momentum weight and bias learning function* (learnngdm), (Beale, M.H. *et al.*, 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, M.H. *et al.*, 2018). La figura 5 presenta un diagrama que muestra la configuración utilizada en el modelo WRF-RNA.

Figura 5. Configuración de la herramienta con uso de los modelos WRF-ARW y de RNA.



Fuente: Elaboración de los autores.

Fueron desarrollados cuatro modelos en base a redes neuronales artificiales (WRF-RNA), que tuvieron como configuraciones, las siguientes:

Modelo 5 – Capa límite: Mellor-Yamada-Janjic, capa de la superficie: *Revised MM*, sin corrección de la velocidad del viento por análisis clúster.

Modelo 6 – Capa límite: Mellor-Yamada-Janjic, capa de la superficie: *Revised MM*, con corrección de la velocidad del viento por análisis clúster.

Modelo 7 – Capa límite: *Yonsei University*, capa de la superficie: *Eta Similarity*, sin corrección de la velocidad del viento por análisis clúster.

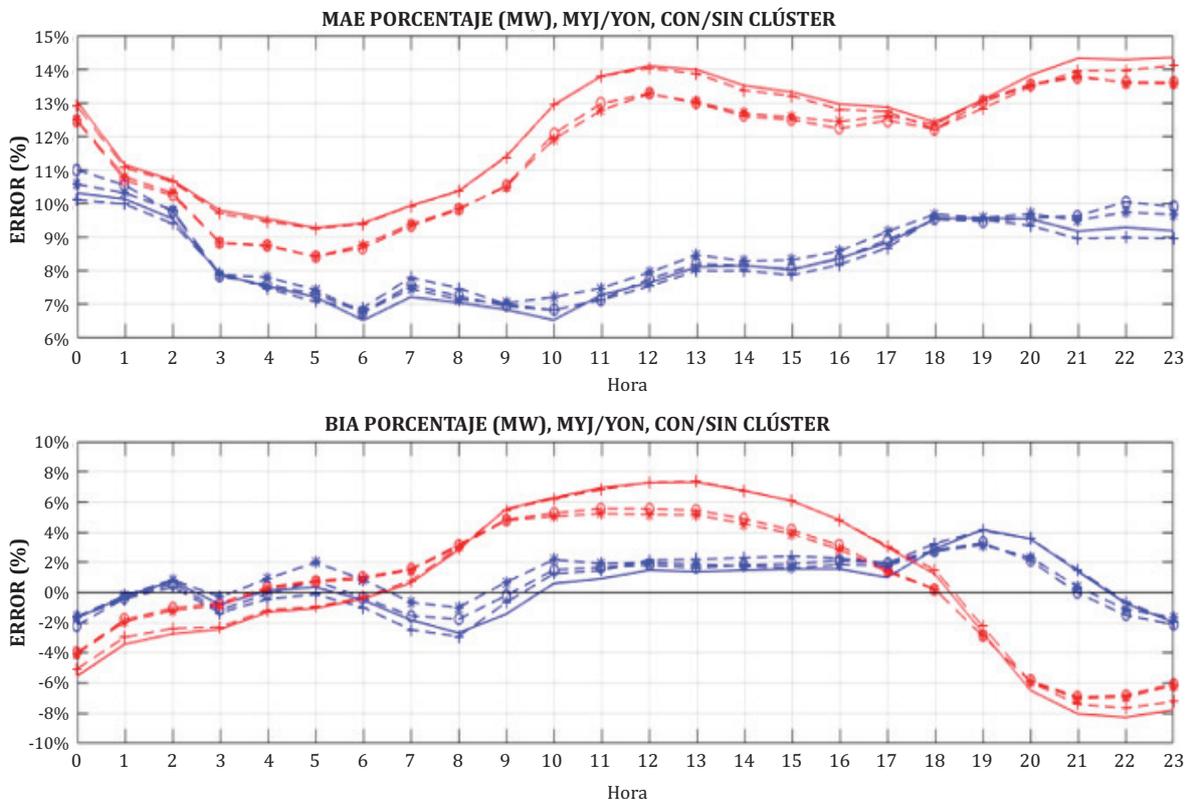
Modelo 8 – Capa límite: *Yonsei University*, capa de la superficie: *Eta Similarity*, con corrección de la velocidad del viento por análisis clúster.

Todos los modelos desarrollados fueron basados en la tesis de maestría del propio autor del trabajo (De Almeida, E., 2019).

RESULTADOS

La figura 6, muestra los valores de error medio absoluto (*mean absolute error*, *mae*, en inglés) y sesgo (*bias*, en inglés) 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 clúster. En base al *bias* de corrección, a cada una de las agrupaciones del análisis clúster 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.

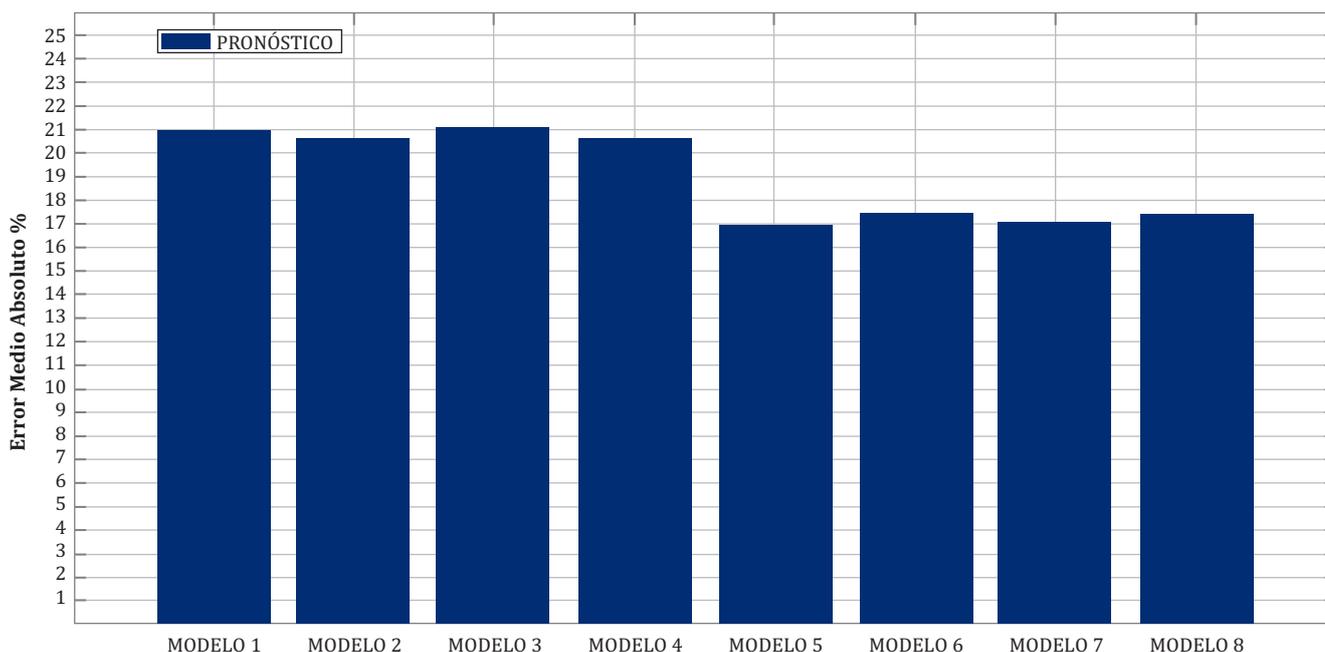
Figura 6. Desempeño de los modelos de pronóstico en base a *bias* y *mae* con modelos WRF-RNA (azul) y WRF-RL (rojo). Los modelos con clúster son representados por “-o” (MYJ) y “-*” (Yonsei) y sin clúster con “-” y “- continua”.



Fuente: Elaboración de los autores.

La evaluación del promedio del error medio absoluto de los ocho distintos modelos de pronóstico desarrollados es presentada en la figura 7.

Figura 7. Evaluación del promedio del error medio absoluto de los ocho modelos de pronóstico desarrollados. Comparación de los Modelos de Pronóstico.



Fuente: Elaboración de los autores.

Los mejores resultados son de los modelos 5 al 8 (WRF-RNA), cuando comparados a los modelos 1 al 4 (WRF-RL), de acuerdo a la figura 7. Los modelos de mejor performance tienen incorporado el uso de RNA's, las cuales tienen una mejor capacidad de pronosticar problemas no lineales.

CONCLUSIONES

Las parametrizaciones físicas de capa límite atmosférica no cambian significativamente los resultados para cada uno de los modelos de pronóstico utilizados. En cuanto al análisis del clúster utilizado, se detecta una mejora para los

modelos en base a regresiones lineales, siendo que no tuvo un aporte para los modelos en base a redes neuronales artificiales. Cuando son comparados los dos modelos desarrollados, se percibe una mejor *performance* del modelo de RNA para todas las configuraciones utilizadas. 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.

AGRADECIMIENTOS

A la empresa eléctrica UTE por la disponibilidad de algunos de los datos utilizados para el desarrollo de este trabajo.

REFERENCIAS

- Ackermann, T. (2005). Wind power in power systems. John Wiley e Sons, Stockholm, Sweden.
- ADME (2018). Informe anual 2017. Administración del Mercado Eléctrico (ADME).
- Beale, M.H., Hagan, M. D., Demuth, H. B., (2018). Neural network toolbox matlab user's guide. Neural Network Toolbox MATLAB User's Guide.
- De Almeida, E. (2019). Pronóstico de energía eólica para horizontes temporales de corto plazo en base a modelo numérico de mesoescala y redes neuronales artificiales. Tesis de Posgrado, Universidad de la República, Montevideo, Uruguay.
- 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.
- Haykin, S. (2009). Neural networks and learning machines, Third Edition. Pearson, Hamilton, Ontario, Canada.
- Jobson, J. (2018). Multiple linear regression. In: Applied multivariate data analysis. Springer, New York.
- Lange, M., Focken. U., (2005). Physical approach to short-term wind power prediction. Springer, Oldenburg, Germany.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. SIAM Journal on Applied Mathematics, 11(2):431-441.
- MIEM-DNE (2008). Política energética 2005-2030. Ministerio de Industria, Energía y Minería (MIEM), Dirección Nacional de Energía (DNE).
- ONS (2018). A implantação do dessem na programação diária da operação e para a formação do preço horário – pldh.
- Ozgonenel, O., Thomas, D., (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.
- Skamarock, W., Klemp, J., Dudhia, J., Gill, D.O., Barker, D., Duda, M., Huang, X., Wang, W., W. Power, J., (2008). A description of the advanced research wrf version 3. NCAR Technical Note 1.
- Ross, T. (2010). Fuzzy logic with engineering applications. Wiley, New York.
- Rumelhart, E., H. G. W. R. (1986b). Learning representations by backpropagating errors. Nature, 323(1):533-536.
- Soman, S.S., Zareipour. H., Malik. O., Mandal, 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.
- Soman, S. (2015). Description of wind turbines blades heights. In 14Th International Conference on Wind Engineering, pages 2435-2438, Porto Alegre, Brazil.
- UTE (2019). Consulta geográfica de fuentes de generación. UTE-DPE (2013). Despachar energía eléctrica. UTE-DPE TM X-72835.
- Varanasi, J., Tripathi. M.M., (2016). Artificial neural network based wind speed and power forecasting in us wind energy farms. In 1s IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems, pages 2435-2438, Sao Paulo, Brasil.
- Wang, X., Guo. P., Huang. X. (2011). A review of wind power forecasting models. Energy Procedia, 12(12):770-778.