

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

Everton de Almeida ^a, Alejandro Gutiérrez ^b, Sandro Camargo ^c

^a *IMFIA-FING-Universidad de la República, Uruguay, ealmeida@fing.edu.uy*

^b *IMFIA-FING-Universidad de la República, Uruguay, aguti@fing.edu.uy*

^c *Universidade Federal do Pampa, Brasil, sandro.camargo@unipampa.edu.br*

RESUMEN: En Uruguay se tiene el 34.43% de la matriz energética de origen eólico. Dada la característica fluctuante del viento en la atmósfera terrestre a escala horaria, es necesario incorporar modelos de pronóstico de energía eólica, de modo de suministrar informaciones 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.

1. 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, la cual se hizo en base a una política energética [1], 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 [2]. Actualmente el 34.43% de la potencia instalada en la matriz energética de Uruguay, es proveniente de la energía eólica [3].

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 [4]. 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) [4] y balance entre demanda y generación de energía eléctrica. 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, [5]. 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)), [6]. 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, [7], entre otras que puedan tener influencia, como la dirección del viento, por ejemplo.

Los pronósticos del viento se dividen en dos tipos, que son el método físico y el método estadístico, [6]. 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 y los de redes neuronales artificiales. A diferencia de los métodos estadísticos de series temporales que son modelos lineales, las RNA resuelven problemas de naturaleza no lineal, [8], como por ejemplo, los pronósticos de energía eólica, [9].

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, [8]. Las RNA se han utilizado principalmente para horizontes de muy corto plazo en la generación de potencia de parques eólicos [10] y velocidades de viento [11]. 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 [12]. 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) [13]. Entre los modelos de mesoescala se destaca el "Weather Research and Forecasting" (WRF) [14], siendo este un modelo de software libre de código abierto, tiene el respaldo de la comunidad científica internacional.

2. METODOLOGÍA

2.1 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. 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 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 periodo, 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 via análisis cluster aportaba un mejor pronóstico para los modelos WRF-RNA y WRF-RL.

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 (datos de potencia de los parques eólicos) y identificar datos inválidos (por mala medición de los sensores) medidos por las torres. La figura 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 1. Parques eólicos (izquierda) y torres de mediciones (derecha) utilizadas para estudio.

2.2 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). 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.

2.3 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) pronosticada a la altura del eje del aerogenerador por el modelo WRF, siendo “ a_p ” el coeficiente calculado por medio de una regresión lineal ($P = a_p X$, con $X = \rho v^3$). 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), [15]. 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. La figura 2 presenta el esquema de un modelo en base a WRF-RL.




Figura 2. Esquema de modelo WRF-RL utilizado para estudio.

2.4 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 [16] 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 [17], 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) [18], la función de aprendizaje fue Gradient descent with momentum weight and bias learning function (learngdm), [19]. 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), [19]. La figura 3 presenta un diagrama que muestra la configuración utilizada en el modelo WRF-RNA.




Figura 3. Configuración de la herramienta con uso de los modelos WRF-ARW y de RNA.

3. RESULTADOS

La figura 4, muestra 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 la 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 4. 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.

4. 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 cluster 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.

5. AGRADECIMIENTOS

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

6. REFERENCIAS

- [1] MIEM-DNE (2008). Política energética 2005-2030. Ministério de Indústria, Energía y Minería (MIEM), Dirección Nacional de Energía (DNE).
- [2] ADME (2018). Informe anual 2017. Administración del Mercado Eléctrico (ADME).
- [3] UTE (2019). Consulta geográfica de fuentes de generación.
- [4] Ackermann, T. (2005). Wind Power in Power Systems. John Wiley e Sons, Stockholm, Sweden.
- [5] 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.
- [6] Wang, X., Guo. P., Huang. X. (2011). A review of wind power forecasting models. Energy Procedia, 12(12):770–778.
- [7] Soman, S. (2015). Description of wind turbines blades heights. In 14Th International Conference on Wind Engineering, pages 2435–2438, Porto Alegre, Brazil.
- [8] Haykin, S. (2009). Neural Networks and Learning Machines, Third Edition. Pearson, Hamilton, Ontario, Canada.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] Lange, M., Focken. U., (2005). Physical Approach to Short-Term Wind Power Prediction. Springer, Oldenburg, Germany.
- [13] Pielke, R. (2013). Mesoscale Meteorological Modeling Academic Press. International Geophysics Series, Colorado, United States.
- [14] 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.
- [15] Jobson, J. (2018). Multiple Linear Regression. In: Applied Multivariate Data Analysis. Springer, New York.
- [16] Ross, T. (2010). Fuzzy Logic with Engineering Applications. Wiley, New York.
- [17] Rumelhart, E., Hinton. G., Williams. R., (1986). Learning representations by backpropagating errors. Nature, 323(1):533–536.
- [18] Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. SIAM Journal on Applied Mathematics, 11(2):431–441.
- [19] Beale, M.H., Hagan, M. D., Demuth, H. B., (2018). Neural network toolbox matlab user's guide. Neural Network Toolbox MATLAB User's Guide.