



## Revisión de literatura de modelos computacionales para la predicción de la velocidad del viento de 2004 a 2016

### A survey of computational models for wind speed forecasting from 2004 to 2016

**Carolina Tripp-Barba**

Facultad de Informática Mazatlán, Universidad Autónoma de Sinaloa, México

ctripp@uas.edu.mx

ORCID: 0000-0002-4811-0247

doi: <https://doi.org/10.36825/RITI.08.15.004>

Recibido: Octubre 19, 2019

Aceptado: Febrero 25, 2020

**Resumen:** El pronóstico de la velocidad del viento es un tema ampliamente investigado en la actualidad. Un factor clave a tener en cuenta es su importancia en el diseño y el cálculo de estructuras para edificios de tamaño considerable que se construirán en zonas de huracanes de alto riesgo. Otra rama de esta línea de investigación incluye su utilidad en la predicción de energía eólica, que no es un tema para discutir en este artículo. Aquí se presenta una clasificación de modelos computacionales para el pronóstico de la velocidad del viento de acuerdo con la técnica matemática utilizada para el pronóstico y basada en la revisión de la literatura. Las técnicas utilizadas para clasificar son: regresión lineal multivariante, redes neuronales artificiales, series de tiempo, lógica difusa y el proceso gaussiano. A lo largo del desarrollo de esta investigación, las redes neuronales artificiales y las aplicaciones de lógica difusa se identificaron como futuras líneas de investigación combinadas con un trabajo eficiente de minería de datos.

**Palabras clave:** *Modelos Computacionales, Modelos de Pronóstico, Velocidad del Viento, Revisión de Literatura.*

**Abstract:** Wind speed forecast is a topic broadly researched in the present day. Its importance in the design and calculations of structures for considerably sized buildings to be built in high risk hurricane zones is a key factor to consider. Another branch off this line of research includes its utility in Eolic energy prediction, which is not a subject to discuss in this article. Here a classification of computational models for wind speed forecasting is presented according to the mathematic technique used for forecasting and based on literature review. The techniques used to classify are: multivariate lineal regression, artificial neural networks, time series, fuzzy logic, and the Gaussian process. Throughout the development of this research, artificial neural networks and fuzzy logic applications were identified as future lines of research both combined with efficient data mining work.

**Keywords:** *Computational Models, Forecasting Models, Wind Speed, Literature Review.*

#### 1. Introducción

Determinar la velocidad del viento en zonas donde se realizarán construcciones de considerable envergadura es un factor importante a tener en cuenta en el cálculo estructural de edificios. Para el diseño y cálculo de

edificaciones altas tradicionalmente se incluye la variable viento desde la perspectiva de sus datos históricos; por ejemplo, dirección y velocidades máximas medidas en una región. Desde hace muchos años se han realizado investigaciones tendientes a predecir, con métodos racionales, la velocidad del viento en muy corto, corto, mediano y largo plazo, pero hasta la fecha no han sido un sustento permanente como uno de los múltiples factores que determinan el diseño y cálculo en la construcción. En [1] se muestran resultados de una investigación publicada en el año de 1969, donde se aplica la técnica de regresión lineal para analizar la velocidad del viento. En 1935, en [2] se realizaron pruebas de laboratorio para estudiar la presión del viento en torres de celosías.

Además de ser útil para la elaboración de normas y reglamentos de construcción, considerando la seguridad; la predicción de la dirección y la velocidad del viento son variables determinantes en la instalación de parques eólicos. Una adecuada predicción de estas variables influye en la cantidad de energía que podría generar. Pero la irregularidad en la velocidad del viento da lugar a variabilidad e incertidumbre al utilizarlo como fuente de energía [3]. La naturaleza caótica del viento ha dado lugar a la implementación de todo tipo de medios y métodos para tratar de entenderlo y pronosticarlo; en [4] se sugiere un modelo difuso para la predicción de la velocidad del viento y la energía eléctrica producida en un parque eólico, este modelo fue entrenado usando un algoritmo genético.

En [5] consideraron la humedad relativa y presión atmosférica; en [6] la radiación solar, presión atmosférica y temperatura fueron los predictores. En las dos investigaciones mencionadas, la velocidad del viento es la variable dependiente. En la predicción de la velocidad del viento es necesario analizar sistemas caóticos (complejos y dinámicos), que, a pesar de no incluir un gran número de variables, éstas interactúan entre sí formando relaciones con nuevas propiedades que no deben estudiarse aisladamente (propiedades emergentes), es indispensable el apoyo de equipos computacionales para la solución eficiente de este tipo de problemas. Este trabajo tiene como objetivo principal proponer una clasificación de los modelos de predicción de la velocidad del viento implementados con equipo de cómputo, con base en una revisión de literatura.

El resto del trabajo se estructura de la siguiente manera: en la Sección 2 se propone una clasificación de los trabajos analizados para esta investigación, considerando los modelos utilizados con apoyo de computadora. En la 3 se expone una tabla comparativa basada en la clasificación propuesta. La Sección 4 menciona las tendencias futuras de esta línea de investigación. Finalmente, en la Sección 5 se analizan las conclusiones a este trabajo.

## 2. Propuesta de clasificación

En las bases de datos electrónicas IEEE Xplore, Elsevier, Springer Link y ACM se realizaron búsquedas de las cadenas de texto *wind forecasting*, *wind prediction*, *pronóstico de viento* y *predicción de viento* en congresos, revistas y libros, incluidos capítulos de libro. Se descartaron los resultados irrelevantes para el tema, además de los que presentaban un enfoque específico hacia la predicción del viento con miras a producir o mejorar la producción de energía. Esta investigación se orientó específicamente en analizar los artículos publicados en las bases de datos mencionadas cuyo objetivo es la implementación de modelos matemático-computacionales en la predicción de la velocidad del viento.

En su gran mayoría los resultados arrojados por las búsquedas fueron publicaciones relacionadas con la predicción de la velocidad del viento para la producción de energía eólica. En nivel intermedio, en cuanto a la cantidad de resultados encontrados, están los artículos de investigación en laboratorio: túneles de viento, turbinas, etcétera. Los documentos de interés para esta investigación son una cantidad reducida. En la base de datos de la ACM la búsqueda no resultó en algún trabajo apropiado. De las bibliotecas electrónicas IEEE Xplore, Elsevier y Springer Link se consideraron finalmente los trabajos, con los cuales se realizó la revisión de literatura aquí expuesta.

Los trabajos se dividieron de acuerdo a la técnica de modelación utilizada para la predicción de la velocidad del viento. La agrupación de los trabajos tiene que ver con la cantidad de artículos que implementan cada técnica y no con la orientación matemática de cada una de ellas. Los grupos se dividieron en regresión lineal multivariada (RLM), redes neuronales artificiales (RNA), series de tiempo (ST), lógica difusa (LD) y proceso de Gauss (PG).

### 3. Técnicas de modelación

#### 3.1. Lógica Difusa (LD)

En [5] los autores presentan un método para predecir la velocidad del viento, en el cual la energía generada por el viento depende más eficientemente y ayuda a evitar tanto costos de sobreproducción como de subproducción. Esto puede ser logrado mediante métodos estadísticos en los cuales una gran cantidad de datos son recolectados y analizados en una relación funcional usando modelos de regresión multivariable. Este artículo presenta una relación estadística de los factores que influyen en la velocidad del viento en una región particular. Las variables consideradas son la humedad relativa, la presión atmosférica y la temperatura promedio.

En [10] se presenta un método de predicción para obtener los puntos específico para pronosticar el valor de la velocidad del viento a partir de datos históricos. Utilizando el coeficiente de correlación de Pearson para mostrar la relatividad entre los puntos de medidas adyacentes, se introduce el método de análisis de regresión basado en el coeficiente de correlación, los autores eligen los datos de velocidad del viento de diez puntos en un campo de viento real para simular y verificar este método. Los resultados de sus simulaciones muestran que ese método puede garantizar la exactitud de la predicción de viento, y puede mejorar la redundancia y fiabilidad de los equipos de medición de viento de manera efectiva.

En el estudio presentado en [14], la velocidad del viento fue modelado por los métodos de regresión lineal (LR, *Linear Regression*), regresión no lineal (NLR, *Non Linear Regression*) y red neural artificial (ANN, *Artificial Neural Network*). Se construyó estructura de alimentación de tres capas de la red neuronal artificial y se utilizó un algoritmo de retro propagación para la formación de las redes neuronales. Para conseguir simulaciones exitosas, en primer lugar, los coeficientes de correlación entre todas las variables meteorológicas (velocidad del viento, temperatura ambiente, presión atmosférica, humedad relativa y precipitación) fueron calculadas tomando variables cada vez en cada cálculo. Todas las variables independientes se agregaron al modelo de regresión simple. Luego, se aplicó el método por etapas de regresión múltiple para la selección de la *mejor* ecuación de regresión (o modelo). Por lo tanto, las mejores variables independientes fueron seleccionadas para los modelos LR y NLR y además fueron utilizados en la capa de entrada de la ANN. Los resultados obtenidos por todos los métodos se compararon entre sí. Por último, se encontró que el método de ANN proporciona un mejor desempeño que los métodos de LR y NLR.

#### 3.2. Redes Neuronales Artificiales (RNA)

La energía eólica es una fuente de energía y la producción de energía eólica inagotable ha estado creciendo rápidamente en los últimos años. Sin embargo, la energía eólica tiene un carácter no planificable debido a las variaciones de velocidad del viento. Por lo tanto, la predicción de la velocidad del viento es un requisito indispensable para los operadores del sistema eléctrico. En [7] se predice un parámetro de velocidad del viento en una tupla de  $N$  entradas utilizando una clasificación de  $k$  vecinos cercanos ( $k$ -NN) y análisis de los efectos de parámetros de entrada, vecinos cercanos y métricas de distancia sobre la predicción de la velocidad del viento. El modelo de clasificación  $k$ -NN fue desarrollado utilizando las técnicas de programación orientada a objetos e incluye métricas de distancia Manhattan y Minkowski excepto por la métrica de distancia Euclidiana al contrario de la literatura. El modelo de clasificación  $k$ -NN que utiliza la dirección del viento, temperatura del aire, la presión atmosférica y los parámetros de humedad relativa en un espacio de 4 tuplas logra la mejor predicción de velocidad del viento para  $k = 5$  en la métrica de distancia Manhattan. Por otro lado, el modelo de clasificación  $k$ -NN, que utiliza la dirección del viento, temperatura del aire y los parámetros de presión atmosférica en una entrada de 3 tuplas dio la peor predicción de velocidad del viento para  $k = 1$  en la métrica de distancia Minkowski.

Es importante mejorar la precisión de las predicciones de velocidad del viento para la gestión de parques eólicos y para la conversión de la energía eólica en electricidad. Sin embargo, debido a la caótica e intrínseca complejidad de los parámetros del clima, la predicción de los datos de velocidad del viento usando diferentes patrones es difícil. En [9] se propone un modelo híbrido denominado SAM-ESM-RBFN para capturar los diferentes patrones y obtener una mejor predicción. Este modelo se basa en los métodos SAM (*Seasonal Adjustment Method*), ESM (*Exponential Smoothing Method*) y RBFN (*Radial Basis Function Neural Network*).

Para evaluar el funcionamiento de la propuesta se utilizó información de dos estaciones meteorológicas de China. El modelo SAM-ESM-RBFM mejora el comportamiento de los siguientes modelos: *Holt-Winters Model* (HWM), *Multilayer Perceptron Neural Network* (MLP), ESM, RBFN, híbrido SAM-ESM, híbrido SAM-RBFN e híbrido ESM-RBFN.

Dos nuevos enfoques para la predicción de la velocidad del viento desarrollan en [12] mediante la integración del modelo *single multiplicative neuron model* y los filtros iterativos no lineales para la actualización de la secuencia de la velocidad del viento con precisión. En los métodos presentados, un modelo no lineal *state-space* es formada primero basado en el modelo *single multiplicative neuron model* y luego se emplean los filtros iterativos no lineales para llevar a cabo la estimación dinámica del estado de la secuencia de la velocidad del viento con una incertidumbre estocástica. Los enfoques sugeridos son demostrados utilizando tres grupos de datos de velocidad de viento y han sido comparados con una media de auto-regresión móvil, la red neuronal artificial, la regresión del núcleo basada en aprendizaje activo residual y métodos sencillos del modelo de neuronal multiplicativo. La propuesta presentada presenta un mejor rendimiento mejor para la predicción de la velocidad del viento por hora que otras tecnologías.

El objetivo en [13] es cuantificar la incertidumbre en la predicción derivada tanto de los datos de entrada y el modelo de predicción. Se presenta un modelo de referencia de intervalos de series de tiempo basado en un enfoque de aprendizaje de datos, más específicamente un perceptrón multicapa NN (*Neural Networks*). Se realizó la demostración del método propuesto en dos casos de estudio: 1) un estudio de caso sintético, con 5 min de datos simulados y 2) un estudio de caso real, que implican mediciones de la velocidad del viento por hora. En los dos casos, la predicción a corto plazo (1-h y diario, respectivamente) se lleva a cabo teniendo en cuenta tanto la incertidumbre en la estructura del modelo y la variabilidad (dentro de horas y durante todo un día, respectivamente) en las entradas. Los resultados obtenidos demuestran que el enfoque de valor de entrada es capaz de capturar la variabilidad en los datos de entrada con la cobertura requerida.

En [16] se desarrolla y evalúa los modelos de predicción de velocidad del viento para la ciudad de Jeju basados en redes neuronales artificiales, con el objetivo de integrar energías renovables en los sistemas de potencia. Modelos de redes neuronales de capa 3 toman el patrón de formación apropiada de los datos históricos acumulados durante los últimos 10 años. El modelo de red neural artificial para registros mensuales muestra un error de rastreo menor al 5%, lo cual considerarse como ruido blanco. Usando esta predicción, el centro de control de toda la ciudad puede hacer que el calendario para las instalaciones de generación de energía que utilizan principalmente combustibles fósiles.

Los autores en [17] aseguran que las combinaciones de modelos físicos y estadísticos para la predicción de velocidad del viento se utilizan con frecuencia para la gestión de parques eólicos. Las redes neuronales artificiales se pueden utilizar en estos modelos como un paso final para obtener predicciones de velocidad del viento más precisas. El objetivo de su trabajo fue determinar el potencial de la unidad de producto redes neuronales evolutivos (EPUNNs) para mejorar la exactitud y la interpretación de estos sistemas. Un sistema previo fue modificado para reemplazar una multicapa por una EPUNN. La baja complejidad del EPUNN permite la interpretación de la relación entre la velocidad del viento y las diferentes variables seleccionadas como entradas.

En [18] se revisa la metodología para la predicción de la velocidad del viento con el modelo ARMA (*Autoregressive Moving Average Model*). Se analizan los procesos de verificación de transformación, normalización, estimación y diagnóstico y se introduce una transformación de probabilidad discreta para deshacer el proceso de transformación necesario para calcular los parámetros de media automática y autorregresiva del modelo ARMA. Este modelo se utilizó como una herramienta de predicción y se ha comparado con el algoritmo de entrenamiento de red neuronal artificial de retropropagación (BP-ANN, *Artificial Neural Network training by Back-Propagation algorithm*). De acuerdo con los resultados obtenidos, el modelo ARMA+DPT (*Discrete Probability Transformation*) presenta errores promedio de RMSE (*Root Mean Square Error*) entre 0.90 y 1.89 m/s y MABE (*Mean Bias Error*) entre 0.63 y 1.39 m/s, mientras que el modelo BP-ANN presentan errores más altos de RMSE, entre 0,95 y 2,05 m/s y mayores errores promedio de MABE, entre 0,72 y 1,56 m/s, para la predicción de intervalos entre 1 y 10 horas en adelante, respectivamente. ARMA+DPT en ciertos casos puede mejorar el BP-

ANN hasta 17,71%; sin embargo, en otros casos el error BP-ANN puede ser 0,9% menor que el modelo ARMA+DPT.

En [21] se enfocan en la predicción de la velocidad del viento en parques eólicos, utilizando la información espacial de las estaciones de medición remotas. Debido a la complejidad temporal del problema, se emplearon redes neuronales recurrentes locales con dinámica interna, como modelos de pronóstico avanzado. Para mejorar el rendimiento de la predicción, la tarea de entrenamiento se lleva a cabo utilizando algoritmos de aprendizaje en línea basados en el enfoque de error de predicción recursiva (RPE, *Recursive Prediction Error*). En primer lugar se desarrolló un esquema de aprendizaje global de RPE (GRPE) en el que se actualizan simultáneamente todos los pesos. A continuación, a través del agrupamiento de pesos se diseñó un método simplificado, el RPE desacoplado (DRPE), con demandas computacionales reducidas. Las derivadas parciales requeridas por los algoritmos de aprendizaje se derivan utilizando el enfoque de modelo adjunto, adaptado a la arquitectura de las redes utilizadas. La eficacia del enfoque propuesto en este trabajo fue probada en un problema de parques eólicos del mundo real, donde se buscan estimaciones de velocidad del viento de varias etapas antes de 15 min a 3 h. Los resultados de simulación demuestran que los modelos de pronóstico recurrentes superan a otros tipos de modelos estáticos neurales y neuro-difusos probados en el mismo problema. Además, proporciona un rendimiento ligeramente inferior en comparación con un modelo recurrente neuro-difuso más complejo que explora la información de dirección del viento.

Un método de fusión para la predicción a corto plazo (hasta 6 horas de anticipación) de la velocidad del viento se presentó en [22]. Las redes neuronales (NN) se utilizan para determinar la mejor combinación no lineal de tres predictores en diferentes tiempos. Los modelos predictivos incluyen la persistencia, la red neuronal artificial y los predictores basados en NWP (*Numeric Weather Prediction*). Los pronosticadores de velocidad del viento incluyen un modelo ingenuo; un modelo físico y un modelo de red neuronal artificial diseñado específicamente. Los resultados muestran que la combinación de tres pronosticadores diferentes conduce a mejoras sustanciales de rendimiento.

Un modelo de computación híbrida basada en redes neuronales para la predicción de la velocidad del viento en sistemas de energía renovable se presenta en [23]. Para aumentar la precisión de la predicción de la velocidad del viento, se propone un modelo de computación híbrido. El modelo propuesto es probado en datos de viento en tiempo real. El objetivo es predecir la velocidad exacta del viento basada en el modelo de computación híbrido propuesto, que integra mapas de característica de auto-organización (SOM, *Self Organizing Maps*) y la red Perceptron de múltiples capas (MLP, *Multi-layer Perceptron Network*). Las ventajas clave incluyen mayor precisión y error mínimo. El modelo de cálculo híbrido propuesto tiene ventajas significativas sobre los modelos convencionales MLP, BPN y RBF. Los siguientes resultados se obtuvieron en sus experimentos: (a) El modelo de computación híbrido basado en redes neuronales es capaz de predecir la velocidad de viento; (b) Mediante la combinación de SOM y MLP, el modelo de computación híbrido muestra una mejor precisión con RMSE (*Root Means Squared Error*) de 0.0828; (c) El modelo híbrido propuesto es definitivamente un estándar más alto cuando se compara con los modelos como MLP convencional (*Conventional MPL Network*), BPN (*Back Propagation Neural Networks*) y RBFN (*Radial Basis Function Neural Network*). La predicción de la velocidad del viento puede mejorar la calidad de la predicción, así como la tasa de convergencia.

La investigación en [25] introduce el concepto y la práctica de las arquitecturas de redes neuronales para la predicción de la velocidad del viento en parques eólicos. El método de predicción de la velocidad del viento ha sido analizado utilizando red de propagación posterior (BPN, *Back Propagation Network*) y red de función de base radial (RBFN, *Radial Basis Function Network*). La red neuronal artificial (ANN, *Artificial Neural Network*) se utiliza para desarrollar una arquitectura adecuada para predecir la velocidad del viento en parques eólicos. La clave de la predicción de la velocidad del viento es la selección racional del modelo de pronóstico y la optimización efectiva del rendimiento del modelo. Para verificar la efectividad de la arquitectura de red neuronal, se realizaron simulaciones de datos de viento en tiempo real con diferentes alturas de molino de viento. Debido a la fluctuación y la no linealidad de la velocidad del viento, la predicción exacta de la velocidad del viento juega un papel importante en el control operacional de parques eólicos. Las principales ventajas de RBFN incluyen mayor precisión, reducción del tiempo de entrenamiento y un mínimo de errores. Los resultados experimentales muestran

que RBFN tiene ventajas significativas sobre los modelos existentes, como son: (1) Estabilidad y exactitud mejoradas de la red; (2) Reduce el tiempo de entrenamiento y el error cuadrático medio y (3) Más adecuado para la predicción de la velocidad del viento en parques eólicos. La evaluación de la arquitectura de la red neuronal se llevó a cabo durante un periodo de 1 año con datos de viento en tiempo real obtenidos de una granja de viento. Este análisis de rendimiento ayuda a los operadores de los parques eólicos a predecir la velocidad del viento con precisión

La predicción de la velocidad del viento en la capa límite atmosférica es importante para la evaluación de la energía eólica, el lanzamiento de satélites y la aviación, etc. Existen algunas técnicas disponibles para la predicción de la velocidad del viento, que requieren un número mínimo de parámetros de entrada, ajuste de curvas, modelo de velocidad móvil integrada regresiva (ARIMA), extrapolación con función periódica y redes neuronales artificiales (ANN). Estos métodos requieren velocidades de viento de horas anteriores como entrada. En [29] se ha descubierto que la velocidad del viento se puede predecir con éxito utilizando solo el conocimiento previo de la velocidad del viento mediante técnicas de regresión y redes neuronales. La predicción de la velocidad del viento mejora si se supone que la velocidad del viento es una función de la velocidad del viento anterior y la hora local.

En [30] una arquitectura DNN (*Deep Neural Network*) de capa oculta compartida en la que las capas ocultas se comparten entre los dominios y las capas de salida son diferentes en cada dominio, se utiliza para el aprendizaje de transferencia. El modelo fusiona los datos de diferentes parques eólicos en diversas regiones. Los resultados muestran que la arquitectura propuesta es de gran beneficio para un parque eólico con datos insuficientes. También se demuestra que cuando no hay muchos datos de entrenamiento, los modelos DNN se comportan peor que otros modelos poco profundos, como SVR (*Support Vector Regression machines*) y ELM. Cuando los datos son suficientes, es efectivo cuando se combinan las estrategias de pre-entrenamiento supervisado y no supervisado SDA. Para construir las redes neuronales profundas en este estudio, se utilizaron datos de solo cuatro parques eólicos ubicados en el norte de China. Aunque las características de variación del viento en diferentes sitios son diferentes debido al clima, el terreno, la topografía, etc., el modelo de transferencia es efectivo.

En los modelos de redes neuronales artificiales (ANN) tradicionales, a menudo se pasa por alto la importancia relativa de las variables meteorológicas de entrada. En [31] se presenta un caso de estudio para modelar los valores mensuales de velocidad del viento utilizando datos meteorológicos (presión atmosférica, temperatura del aire, humedad relativa y precipitación), donde el estudio incluye una estimación de la importancia relativa de estas variables. Los datos medios mensuales registrados están disponibles en un sitio de medición en Tabriz, Azerbaiyán, Irán, para el período de 2000 a 2005. El método utilizado en este artículo muestra la importancia relativa de cada parámetro de entrada meteorológica que afecta la velocidad del viento, mostrando que la presión del aire y la precipitación son los parámetros más influyentes con valores aproximados de 40 y 10%, respectivamente.

### 3.3. Series de Tiempo (ST)

Debido a la naturaleza irregular de la producción de energía eólica, una predicción confiable representa un importante desafío para los operadores de sistemas de potencia, en [3] los autores investigan sobre el uso del predictor Grey para la predicción de energía eólica. Sin embargo, este modelo se caracteriza por la presencia de algunos *overshoots* en la predicción de las series de tiempo. Estos pueden resultar en la predicción de series de tiempo de la velocidad del viento peores que las del modelo persistente. El modelo Grey promedio alcanzó el nivel más alto de la previsión de velocidad del viento y de precisión de la predicción de energía eólica, en comparación con el modelo persistente y los otros modelos Grey presentados, al tiempo que demuestra una muy buena característica de seguimiento y una reducción en la ocurrencia de *overshoots*.

En [6] se presenta la generación de un modelo no-lineal autorregresivo exógeno (NARX, por sus siglas en inglés, *Nonlinear AutoRegressive eXogenous model*) para la previsión de la velocidad del viento durante una hora. Una muestra de datos meteorológicos por hora fue tomada durante un año para utilizarse para la generación del modelo. Las variables medidas fueron las siguientes: velocidad del viento, dirección del viento, radiación solar, presión y temperatura. Todas las mediciones fueron tomadas por la Comisión Federal de Electricidad (CFE) de La

Mata, en el estado de Oaxaca, México. Los resultados mostraron que el modelo NARX es más preciso comparado con un modelo de una variable y un modelo no-lineal autorregresivo (NAR, *Nonlinear AutoRegressive model*), lo que refleja la importancia de la inclusión de variables meteorológicas adicionales en los modelos de predicción de velocidad del viento.

La mayoría de las técnicas descritas en la literatura para la predicción de la velocidad del viento usan modelos lineales de series temporales. Aunque son atractivos por su eficiencia computacional y simplicidad, su precisión de predicción más allá de unos pocos pasos de tiempo es generalmente muy pobre. En [19] los autores han demostrado a través de cálculos numéricos que la precisión de predicción de modelos lineales simples puede ser notablemente mejorada, incluso para los pronósticos más allá de una semana, mediante la descomposición adecuada de las series de tiempo antes de la predicción. Las predicciones de la velocidad del viento por un modelo auto-regresivo combinado con la descomposición basada en wavelet de las series temporales se consideran exactas dentro de un error promedio de 7e8% para las predicciones hasta 3 días antes. Un análisis estadístico de las predicciones hechas en 234 lugares diferentes revela que la descomposición de series temporales mejora la precisión de los modelos AR (*Auto-Regressive*) en un promedio del 60.15% para las predicciones de un día y hasta un 18.23% para las predicciones semanales.

En [20], se han construido modelos ARMAX lineales y no lineales para una previsión de 10 min para la velocidad del viento y se ha probado el rendimiento de los modelos para una predicción de varios pasos adelante. Este artículo ha explotado el hecho de que la aparición y la intensidad del viento dependen de varios parámetros atmosféricos como la temperatura, la radiación solar, la dirección del viento, etc. Se formularon diferentes modelos lineales y no lineales ARMA (*Auto Regressive Moving Average*) y ARMAX (*ARMA models with eXogenous*) basados en estos parámetros utilizando dos conjuntos de datos diferentes; el desempeño de estos modelos se evaluó utilizando las métricas MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*) y MAPE (*Mean Absolute Percentage Error*). Los modelos ARMAX construidos en función de la dirección del viento ofrecen el mejor rendimiento en comparación con otros. El rendimiento de los modelos ARMAX basados en la radiación solar y la temperatura es menor en comparación con los correspondientes modelos ARMA. El rendimiento de ARMAX basado en tendencias lineales de datos de velocidad del viento en los últimos dos años y el modelo ARMAX basado en la cizalladura del viento muestran un mejor rendimiento. También se observa que los modelos no lineales construidos utilizando el algoritmo SMOReg y el algoritmo M5R tienen mejores resultados que los demás. Según los autores una buena selección de variables exógenas y un algoritmo adecuado desempeñan un papel importante en el desarrollo de modelos de pronóstico precisos de la velocidad del viento. Los modelos híbridos donde los parámetros de los modelos auto-regresivos lineales y no lineales se mediante técnicas meta-heurísticas resultan en una mayor exactitud y por lo tanto es un área de investigación a explorar.

Una nueva técnica para predecir la velocidad y la dirección del viento es presentada en [24]. Esta técnica se basa en el uso de un modelo lineal basado en series de tiempo que relaciona el intervalo predicho con los datos correspondientes de uno y dos años. La exactitud del modelo para predecir las velocidades del viento y las direcciones de hasta 24 horas antes se ha investigado usando dos conjuntos de datos registrados durante el invierno y la temporada de verano en la estación meteorológica de Madison. Los resultados presentados revelan la efectividad y la precisión de la nueva técnica propuesta para la predicción de velocidad y dirección del viento. Los modelos propuestos predicen velocidades del viento para un día con una mejora sobre el modelo persistente de hasta 54.4% para el MAE (*Mean Absolute Error*) y hasta 55.3% para el RMSE (*Root Mean Squares of Errors*). Además, los modelos propuestos predicen las direcciones del viento con un día de anticipación, con una mejora respecto al modelo persistente hasta el 45.3% para el MAE y hasta el 26% para el RMSE. Por otra parte, los resultados revelaron que los modelos propuestos producen dispersión reducida, mayores coeficientes de correlación y mayores factores de escala que los producidos por el modelo persistente. Los resultados también revelaron que, para la estación meteorológica de Madison, los modelos propuestos generan mejores resultados durante la temporada de verano que los generados durante la temporada de invierno. Esto se debe a que los datos registrados durante la temporada de verano están más relacionados entre sí que los registrados durante la temporada de invierno. Los modelos propuestos requieren grandes dispositivos de almacenamiento de datos, que hoy en día están disponibles debido a la rápida revolución en las herramientas informáticas y dispositivos de almacenamiento electrónico.

En [26] se compara el uso de las series de tiempo de la energía eólica y la velocidad del viento con la regresión de RF (*Random Forests*), SVR (*Support Vector Regression*) y *k*-NN (*k-Nearest Neighbors*). Si bien las características de potencia y velocidad contienen una cantidad esencial de información para la tarea de predicción, en este artículo los autores muestran experimentalmente que ambas deben combinarse para mejorar el error de predicción. Y que este se puede aumentar aún más al incluir las diferencias de las mediciones de potencia y velocidad. Además, proponen un método conjunto para la predicción de la energía eólica que emplea un regresor de RF y un SVR.

En [27], se presentó la predicción de la velocidad del viento y la potencia de la turbina eólica en intervalos de tiempo corto (10 s) hasta 1 minuto en el futuro. Se utilizaron algoritmos de alisamiento exponencial y extracción de datos para establecer modelos de predicción de velocidad del viento basados en los datos de la turbina eólica. Se consideraron tres modelos diferentes de predicción de potencia. El primer modelo (modelo uno) aprendió la función de coeficiente de potencia de los datos de la turbina. El segundo modelo (modelo dos) usó los valores predichos del par del generador, el ángulo de paso de la pala y la velocidad del viento para predecir la potencia de salida de la turbina. El tercer modelo (modelo tres) empleó algoritmos de extracción de datos para predecir la potencia al considerar parámetros similares a los utilizados en el modelo uno. Se analizó el desempeño de los tres modelos; los resultados computacionales confirmaron que el error de predicción de la velocidad del viento aumentaba a medida que el horizonte de predicción se hacía más distante. Una NN (*Neural Network*) ha producido los mejores resultados para la predicción de la velocidad del viento. La precisión de la predicción de la velocidad del viento a los 60 segundos en el futuro fue de aproximadamente el 90%. El modelo dos fue el mejor para predecir el poder. La precisión de predicción del modelo dos fue afectada principalmente por la precisión de predicción de la velocidad del viento y dos parámetros controlables, el par del generador y el ángulo de paso de la pala. La aplicación de este modelo requiere el desarrollo de nuevos enfoques de control. Cada uno de los tres modelos de predicción de potencia analizados en este artículo predijo con precisión la potencia producida por una turbina eólica en horizontes de corto plazo.

Un método de predicción basado en redes wavelet usando MRA-AWNN (*Multi Resolution Analysis - Adaptive Wavelet Neural Network*) se implementó y evaluó mediante simulaciones numéricas usando perfiles de velocidad real del viento en [28]. El método de predicción propuesto incluye resolución múltiple y un análisis de predicción de los componentes de la serie de tiempo estudiada con el objetivo de optimizar el algoritmo de predicción. De hecho, el análisis de previsibilidad de cada componente de la señal descompuesta permite eliminar los componentes con bajo potencial de previsibilidad. Esta operación permite optimizar la complejidad del sistema de predicción sin reducir la precisión. En el caso estudiado en este artículo, se redujeron los recursos computacionales a aproximadamente el 29%, manteniendo un desempeño similar. Estos importantes ahorros en complejidad son muy importantes cuando se prevé la implementación de un sistema de predicción integrado utilizando procesadores digitales.

### 3.4. Lógica Difusa (LD)

En [4] se sugiere un modelo difuso es sugerido para la predicción de la velocidad del viento y la energía eléctrica producida en un parque eólico. El modelo es preparado utilizando un algoritmo genético basado en un esquema de aprendizaje. El conjunto de entrenamiento incluye datos como la velocidad y dirección del viento, los cuales fueron medidos en estaciones meteorológicas en un radio de 30 km. Los resultados de extensas simulaciones mostrados para dos casos de aplicación, proporcionan el pronóstico de velocidad del viento de 30 min a 2 horas delante. Está demostrado que el modelo sugerido logra una adecuada comprensión del problema mientras se exhibe una mejora significativa en comparación con el método persistente.

En [15] se diseña un práctico modelo de predicción de la velocidad del viento usando la teoría de probabilidad difusa. Ya que PFLS (*Probabilistic Fuzzy Logic System*) puede manejar las incertidumbres estocásticas y las incertidumbres deterministas simultáneamente, su integración con el modelo de predicción puede lograr el mejor rendimiento de predicción en el entorno complejo. El diseño desarrollado ayudará a que el modelo de predicción examine a fondo todo tipo de incertidumbres existentes en el proceso. Las simulaciones sobre datos de velocidad



de viento reales muestran que el modelo de predicción de la velocidad del viento propuesta tiene el mejor rendimiento que el del modelo difuso tradicional, el intervalo de modelo difuso de Tipo-2 y el método de redes neuronales. Por lo tanto, el modelo PFLS basado en predicción de la velocidad del viento es una herramienta práctica y prometedora para el uso de la energía eólica bajo incertidumbres complejas.

### 3.5. Proceso de Gauss (PG)

La optimización de la generación de energía eólica y el control del funcionamiento de las turbinas de viento para aprovechar de manera eficiente la energía eólica renovable es una tarea difícil debido a la intermitencia y la impredecible naturaleza de la velocidad del viento, la cual tiene una influencia significativa en la producción de energía eólica. Un nuevo enfoque para la previsión de la velocidad del viento a largo plazo se desarrolla en [8] mediante la *integración de GMCM (Gaussian Mixture Copula Model) y GPR localizada (Gaussian Process Regression)*. El enfoque propuesto GMCM-GPR se demuestra utilizando los datos de velocidad del viento en diferentes localizaciones de parques eólicos y es comparado con los modelos GMCM basado en ARIMA (*Auto-Regressive Integrated Moving Average*) y SVR (*Support Vector Regression*). El modelo propuesto GMCM-GPR demuestra ser altamente efectivo para la predicción precisa a largo plazo, con una alta exactitud y fidelidad. En comparación con los métodos GMCM-ARIMA y GMCM-SVR indica que puede conducir a predicciones más precisas sobre la velocidad del viento.

En [11] se propone un modelo de combinación probabilístico para el de la velocidad del viento a corto plazo. En este enfoque híbrido propuesto se emplea EWT (*Empirical Wavelet Transform*) para extraer información significativa de una serie de velocidades de viento mediante el diseño de un banco de filtros de onda apropiada. El modelo GPR (*Gaussian Process Regression*) se utiliza para combinar pronósticos independientes generados por diversos motores de predicción como: ARIMA (*Autoregressive Integrated Moving Average*), ELM (*Extreme Learning Machine*), SVM (*Support Vector Machine*) y LSSVM (*Least Square SVM*), en una forma no lineal en vez de la forma lineal de uso común. El enfoque propuesto proporciona más información probabilística para las predicciones de la velocidad del viento, además de mejorar la precisión de las previsiones para las predicciones de un solo valor. Los resultados indican que los motores de pronóstico individuales no pronostican constantemente la velocidad del viento a corto y el método de combinación propuesta puede generar un pronóstico más fiable y preciso.

## 4. Tabla de clasificación

En este apartado se clasifican algunos de los artículos de investigación que implementan técnicas de predicción por computadora, desarrollados a nivel mundial por centros de investigación, la industria e instituciones educativas. La Tabla 1 organiza los proyectos más representativos de acuerdo a la técnica matemática utilizada para la predicción de la velocidad del viento, se anexa también la referencia, la principal contribución de la investigación y el estado que guarda actualmente: en proceso (EP), si ha sido implementado (EI) o solamente terminado (T).

**Tabla 1.** Clasificación de trabajos representativos.

<b>Técnica utilizada</b>	<b>Referencia</b>	<b>Principal Contribución</b>	<b>Estado</b>
RLM	N.N. Arjun <i>et al.</i> [5]	Evita la sobreproducción de energía.	EP
ST	T. H. M. El-Fouly <i>et al.</i> [3]	Propone mejoras al modelo tradicional de caja gris	EI
ST	E. Cadenas <i>et al.</i> [6]	Modelo NARX con un desempeño mejorado sobre el modelo de persistencia (11%) y sobre un modelo NAR (4%).	T
LD	I. G. Damousis <i>et al.</i> [4]	Mejora significativamente otros modelos en terrenos planos. En cualquier tipo de terreno, el modelo mejora de 10 a 25% otros modelos conocidos.	EP

RNA	M. Yesilbudak <i>et al.</i> [7]	Presenta un nuevo enfoque basado en la clasificación $k$ -NN para predicción a corto plazo utilizando entradas multitupla.	T
PG	J. Yu <i>et al.</i> [8]	Integración de <i>Gaussian mixture copula model</i> (GMCM) al Procedo de Gauss para construir un modelo de predicción a largo plazo.	T
RNA, ST	J. Wang <i>et al.</i> [9]	Mejora la exactitud de la predicción con un modelo híbrido que implementa técnicas de redes neuronales: <i>radial basis function neural network</i> ; y series de tiempo: <i>seasonal adjustment method</i> y <i>exponential smoothing method</i> .	T
RLM	Y. Wang <i>et al.</i> [10]	Considera como variables para el modelo, datos históricos de velocidad del viento en un punto adyacente.	EP
PG	J. Wang <i>et al.</i> [11]	Propone un modelo de regresión del proceso de Gauss, combinando Modelo Autorregresivo Integrado de Media Móvil (ARIMA), Máquinas de Aprendizaje Extremo (ELM), Máquinas de Vectores de Soporte (SVM) y Máquinas de Vectores de Soporte de Mínimos Cuadrados (LSSVM).	EP
RNA	X. Wu <i>et al.</i> [12]	Integra el modelo de neurona multiplicativa simple y los filtros no lineales iterados para actualizar la secuencia de la velocidad del viento con precisión.	T
RNA	R. Ak <i>et al.</i> [13]	Predicción con datos de entrada en forma de intervalos, cada 5 minutos, a partir de un Modelo autorregresivo de media móvil.	EP
RLM, RNA	M. Bilgili <i>et al.</i> [14]	Obtención de variables clave por medio de RLM, las cuales son utilizadas como datos de la capa de entrada de la RNA.	T
LD	G. Zhang <i>et al.</i> [15]	Considera incertidumbres estocásticas y deterministas para garantizar una mejor predicción en un entorno estocástico complejo.	T
RNA	J. Lee <i>et al.</i> [16]	Desarrolla y evalúa modelos de predicción de velocidad del viento para la ciudad de Jeju, Corea del Sur.	T
RNA	C. Hervás-Martínez <i>et al.</i> [17]	Combina modelos de predicción velocidad del viento físicos y estadísticos; emplea redes neuronales en la etapa final para obtener predicciones más precisas.	EP
RNA	J. M. Lujano-Rojas <i>et al.</i> [18]	Utiliza el modelo ARMA ( <i>Autoregressive Moving Average Model</i> ) y se compara con el algoritmo de entrenamiento de red neuronal artificial de retropropagación (BP-ANN, <i>artificial neural network training by back-propagation algorithm</i> ).	T
ST	D. C. Kiplangat <i>et al.</i> [19]	Propen mejoras basado en las predicciones de la velocidad del viento por un modelo auto-regresivo combinado con la descomposición basada en <i>wavelet</i> de las series temporales.	T
ST	M. Lydia <i>et al.</i> [20]	Se formularon diferentes modelos lineales y no lineales ARMA ( <i>Auto Regressive Moving Average</i> ) y ARMAX ( <i>ARMA models with exogenous</i> ) basados en parámetros como temperatura, la radiación solar, la dirección del viento, etc., utilizando dos conjuntos de datos diferentes; el desempeño de estos modelos se evaluó utilizando las métricas MAE ( <i>Mean Absolute Error</i> ), RMSE ( <i>Root Mean Squared Error</i> ) y MAPE ( <i>Mean Absolute Percentage Error</i> ).	T
RNA	T. G. Barbounis <i>et al.</i> [21]	Desarrollan un esquema de aprendizaje global de RPE (GRPE, <i>global recursive prediction error</i> ) en el que se actualizan simultáneamente todos los pesos. Después, a través del agrupamiento de pesos diseñaron un método simplificado, el RPE desacoplado (DRPE), con demandas computacionales reducidas.	T
RNA	J. L. Cardenas-Barrera1 <i>et al.</i> [22]	Se presentó un método de fusión para la predicción a corto plazo (hasta 6 horas de anticipación) utilizando redes neuronales.	T

RNA	K. Gnana Sheela <i>et al.</i> [23]	Se muestra un modelo de computación híbrida basada en redes neuronales en sistemas de energía renovable.	T
ST	T. H. M. El-Fouly <i>et al.</i> [24]	Uso de un modelo lineal basado en series de tiempo	EI
RNA	K. Gnana Sheela <i>et al.</i> [25]	Introduce el concepto y la práctica de las arquitecturas de redes neuronales en parques eólicos. El método de predicción de la velocidad del viento ha sido analizado utilizando red de propagación posterior (BPN, <i>Back Propagation Network</i> ) y red de función de base radial (RBFN, <i>Radial Basis Function Network</i> ).	EI
ST	J. Heiner mann <i>et al.</i> [26]	Se compara el uso de las series de tiempo de la energía eólica y la velocidad del viento con la regresión de RF ( <i>Random Forests</i> ), SVR ( <i>Support Vector Regression</i> ) y k-NN ( <i>k-Nearest Neighbors</i> ).	T
ST	A. Kusiak <i>et al.</i> [27]	Se utilizaron algoritmos de alisamiento exponencial y extracción de datos; los resultados computacionales confirmaron que el error de predicción de la velocidad del viento aumentaba a medida que el horizonte de predicción se hacía más distante	T
ST	B. Doucoure <i>et al.</i> [28]	Se implementó y evaluó un método de predicción basado en redes <i>wavelet</i> usando MRA-AWNN ( <i>Multi Resolution Analysis - Adaptive Wavelet Neural Network</i> ) mediante simulaciones numéricas usando perfiles de velocidad real del viento.	T
RNA	M. Kulkarni <i>et al.</i> [29]	Se afirma que la velocidad del viento se puede predecir con éxito utilizando solo el conocimiento previo de la velocidad del viento mediante técnicas de regresión y redes neuronales	T
RNA	Q. Hu <i>et al.</i> [30]	Se utiliza una arquitectura DNN ( <i>Deep Neural Network</i> ) de capa oculta compartida en la que las capas ocultas se comparten entre los dominios y las capas de salida son diferentes en cada dominio para el aprendizaje de transferencia.	T
RNA	M. A. Ghorbani <i>et al.</i> [31]	Presenta un caso de estudio para modelar los valores mensuales de velocidad del viento utilizando datos meteorológicos como: presión atmosférica, temperatura del aire, humedad relativa y precipitación.	T

En resumen, podemos observar que fueron un total de 29 los artículos clasificados, de los cuales 22 está terminados, tres fueron terminados y seis se quedaron en proceso de desarrollo. De estos, 15 de las investigaciones utilizaban la técnica de RNA, nueve la de ST, 3 RLM y solamente dos emplearon LD y PG, respectivamente.

Una vez realizado el estudio de las propuestas clasificadas identificamos que una combinación de técnicas como Redes Neuronales Artificiales [32], Series de Tiempo y Minería de Datos [33], como modelo híbrido, sería una propuesta eficiente para elaborar un modelo matemático de predicción de la velocidad del viento. Una adecuada minería de datos ayudaría a recabar las variables clave que inciden en este fenómeno. Se propone que se alimente con estos factores una red neuronal artificial o se implementen series de tiempo y con ello elaborar el modelo matemático.

## 5. Conclusiones

La implementación de técnicas matemáticas para predicción del viento se ha incrementado en años recientes, debido, principalmente, a la necesidad de generación de energía por métodos alternativos (eólica), pero debe considerarse también la importancia de la predicción de este fenómeno en la seguridad de la vida humana al ser factor clave para la construcción de edificios en zonas de alto riesgo de huracanes. Un diseño y cálculo eficaces, considerando las variables más importantes para la seguridad, son un complicado reto a vencer.

Este trabajo propone una clasificación de los modelos de predicción de la velocidad del viento implementados con equipo de cómputo, de acuerdo a la técnica matemática utilizada para el pronóstico y con base en una revisión de literatura.

No obstante que la línea de investigación sobre la predicción de la velocidad del viento es un tema actualmente bastante estudiando, no es posible afirmar que se ha desarrollado un modelo general para pronosticarlo, aún existe un amplio campo por explorar y técnicas matemáticas que aplicar, incluyendo combinaciones de ellas. Durante el desarrollo de esta investigación, pudieron ser identificadas como futuras líneas de investigación la aplicación de redes neuronales artificiales y series de tiempo, ambas combinadas con un eficiente trabajo de minería de datos.

## 6. Referencias

- [1] Gott, E. (1969). Linear Regression of Interlevel Wind Velocities. *IEEE Transactions on Geoscience Electronics*, 7 (1), 44-47. doi: <https://doi.org/10.1109/TGE.1969.271346>
- [2] British Electrical and Allied Industries Research Association. (1935). Wind Pressure on Latticed Towers—Tests on Models. *IEEE Journal of the Institution of Electrical Engineers*, 77 (464), 189-196. doi: <https://doi.org/10.1049/jiee-1.1935.0139>
- [3] El-Fouly, T. H., El-Saadany, E. F., (2012). Grey Predictors for Hourly Wind Speed and Power Forecasting. In: S. Muyeen (Ed.), *Wind Energy Conversion Systems, Green Energy Technology*. London: Springer. doi: [https://doi.org/10.1007/978-1-4471-2201-2\\_9](https://doi.org/10.1007/978-1-4471-2201-2_9)
- [4] Damousis, I. G., Alexiadis, M. C., Theocharis, J. B., Dokopoulos, P. S. (2004). A Fuzzy Model for Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation. *IEEE Transactions on Energy Conversion*, 19 (2), 352-361. doi: <https://doi.org/10.1109/TEC.2003.821865>
- [5] Arjun, N. N., Prema, V., Kumar, D. K., Prashanth, P., Preekshit, V. S., Rao, K. R. (2014). Multivariate Regression models for prediction of wind speed. Presentado en *International Conference on Data Science & Engineering (ICDSE)*, Kochi, India. doi: <https://doi.org/10.1109/ICDSE.2014.6974632>
- [6] Cadenas, E., Rivera, W., Campos-Amezcu, R., Cadenas, R. (2015). Wind speed forecasting using the NARX model, case: La Mata, Oaxaca, México. *Neural Computing and Applications*, 27 (8), 2417-2428. doi: <https://doi.org/10.1007/s00521-015-2012-y>
- [7] Yesilbudak, M., Sagiroglu, S., Colak, I. (2013). A new approach to very short term wind speed prediction using k-nearest neighbor classification. *Energy Conversion and Management*, 69, 77–86. <https://doi.org/10.1016/j.enconman.2013.01.033>
- [8] Yu, J., Chen, K., Mori, J., Rashid, M. M. (2013). A Gaussian mixture copula model based localized Gaussian process regression approach for long-term wind speed prediction. *Energy*, 61, 673-686. doi: <https://doi.org/10.1016/j.energy.2013.09.013>
- [9] Wang, J., Zhang, W., Wang, J., Han, T., Kong, L. (2014). A novel hybrid approach for wind speed prediction. *Information Sciences*, 273, pp. 304–318. doi: <https://doi.org/10.1016/j.ins.2014.02.159>
- [10] Wang, Y., Su, Z. (2015). A Prediction Method for Wind Speed Based on the Correlation Analysis of Measured Data of Adjacent Wind Turbine. En Z, Deng, H. Li (Eds.), *Proceedings of the 2015 Chinese Intelligent Automation Conference. Lecture Notes in Electrical Engineering* (pp 87-95). Berlin: Springer. doi: [https://doi.org/10.1007/978-3-662-46469-4\\_9](https://doi.org/10.1007/978-3-662-46469-4_9)
- [11] Wang, J., Hu, J. (2015). A robust combination approach for short-term wind speed forecasting and analysis e Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy*, 93 (1), 41-56. doi: <https://doi.org/10.1016/j.energy.2015.08.045>
- [12] Wu, X., Zhu, Z., Su, X., Fan, S., Du, Z., Chang, Y., Zeng, Q. (2015). A study of single multiplicative neuron model with nonlinear filters for hourly wind speed prediction. *Energy*, 88, 194-201. doi: <https://doi.org/10.1016/j.energy.2015.04.075>

- [13] Ak, R., Vitelli, V., Zio, E. (2015). An Interval-Valued Neural Network Approach for Uncertainty Quantification in Short-Term Wind Speed Prediction. *IEEE Transactions on Neural Networks and Learning Systems*, 26 (11), 2787-2800. doi: <https://doi.org/10.1109/TNNLS.2015.2396933>
- [14] Bilgili, M., Sahin, B. (2010). Comparative analysis of regression and artificial neural network models for wind speed prediction. *Meteorology and Atmospheric Physics*, 109 (1-2), 61-72. doi: <https://doi.org/10.1007/s00703-010-0093-9>
- [15] Zhang, G., Li, H. X., Gan, M. (2012). Design a Wind Speed Prediction Model Using Probabilistic Fuzzy System. *IEEE Transactions on Industrial Informatics*, 8 (4), 819-827. doi: <https://doi.org/10.1109/TII.2012.2205392>
- [16] Lee, J., Park, G. L., Kim, E. H. (2012). Development of Wind Speed Prediction Model in Jeju City. *Computer Applications for Modeling, Simulation and Automobile*, 341, 20-26, 2012. doi: [https://doi.org/10.1007/978-3-642-35248-5\\_4](https://doi.org/10.1007/978-3-642-35248-5_4)
- [17] Hervás-Martínez, C., Salcedo-Sanz, S., Gutiérrez, P. A., Ortiz-García, E. G., Prieto, L. (2012). Evolutionary product unit neural networks for short-term wind speed forecasting in wind farms. *Neural Computing and Applications*, 21 (5), 993-1005. doi: <https://doi.org/10.1007/s00521-011-0582-x>
- [18] Lujano-Rojas, J. M., Bernal-Agustín, J. L., Dufo-López, R., Domínguez-Navarro, J. A. (2011). Forecast of Hourly Average Wind Speed Using ARMA Model with Discrete Probability Transformation. *Electrical Engineering and Control*, 98, 1003-1010. doi: [https://doi.org/10.1007/978-3-642-21765-4\\_125](https://doi.org/10.1007/978-3-642-21765-4_125)
- [19] Kiplangat, D. C., Asokan, K., Kumar, K. S. (2016). Improved week-ahead predictions of wind speed using simple linear models with wavelet decomposition. *Renewable Energy*, 93, 38-44.
- [20] Lydia, M., Suresh Kumar, S., Immanuel Selvakumara, A., Edwin Prem Kumarc, G. (2016). Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy Conversion and Management*, 112, 115-124. doi: <https://doi.org/10.1016/j.enconman.2016.01.007>
- [21] Barbounis, T. G., Theocharis, J. B. (2007). Locally recurrent neural networks for wind speed prediction using spatial correlation. *Information Sciences*, 177 (24), 5775-5797. doi: <https://doi.org/10.1016/j.ins.2007.05.024>
- [22] Cardenas-Barrera, J. L., Castillo-Guerra, E., Meng, J., Chang, L. (2013). Multi-step-ahead, Short-Term Prediction of Wind Speed Using a Fusion Approach. En J. Ruiz-Shulcloper, G. Sanniti di Baja G. (Eds.), *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2013. Lecture Notes in Computer Science* (pp 83-91). Berlin: Springer. doi: [https://doi.org/10.1007/978-3-642-41827-3\\_11](https://doi.org/10.1007/978-3-642-41827-3_11)
- [23] Gnana Sheela, K., Deepa, S. N. (2013). Neural network based hybrid computing model for wind speed prediction. *Neurocomputing*, 122, 425-429. doi: <https://doi.org/10.1016/j.neucom.2013.06.008>
- [24] El-Fouly, T. H., El-Saadany, E., Salama, M. A. (2008). One Day Ahead Prediction of Wind Speed and Direction. *IEEE Transactions on Energy Conversion*, 23 (1), 191-201. doi: <https://doi.org/10.1109/TEC.2007.905069>
- [25] Gnana Sheela, K., Deepa, S. N. (2013). Performance Analysis of Modeling Framework for Prediction in Wind Farms Employing Artificial Neural Networks. *Soft Computing*, 18 (3), 607-615. doi: <https://doi.org/10.1007/s00500-013-1084-9>
- [26] Heinermann, J., Kramer, O. (2015). Short-Term Wind Power Prediction with Combination of Speed and Power Time Series. En S. Hölldobler, R. Peñaloza, S. Rudolph (Eds.), *KI 2015: Advances in Artificial Intelligence. KI 2015. Lecture Notes in Computer Science* (pp 100-110). Cham: Springer.
- [27] Kusiak, A., Zhang, Z. (2010). Short-Horizon Prediction of Wind Power: A Data-Driven Approach. *IEEE Transaction on Energy Conversion*, 25 (4), 1112-1122. doi: <https://doi.org/10.1109/TEC.2010.2043436>
- [28] Doucoure, B., Agbossou, K., Cardenas, A. (2011). Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. *Renewable Energy*, 92, 202-211. doi: <https://doi.org/10.1016/j.renene.2016.02.003>
- [29] Kulkarni, M., Patil, S., Rama, G. V., Sen, P. N. (2008). Wind speed prediction using statistical regression and neural network. *Journal of Earth System Science*, 117 (4), 457-463.
- [30] Hu, Q., Zhang, R., Zhou, Y. (2015). Transfer learning for short-term wind speed prediction with deep neural networks. *Renewable Energy*, 85, pp. 83-95. doi: <https://doi.org/10.1016/j.renene.2015.06.034>
- [31] Ghorbani, M. A., Khatibi, R., Hosseini, B., Bilgili, M. (2013). Relative importance of parameters affecting wind speed prediction using artificial neural networks. *Theoretical and Applied Climatology*, 114, 107-114. doi: <https://doi.org/10.1007/s00704-012-0821-9>

- [32] Deligiorgi, D., Philippopoulos, K., Kouroupetroglou, G. (2013). Artificial Neural Network Based Methodologies for the Estimation of Wind Speed. En F. Cavallaro (Eds.), *Assessment and Simulation Tools for Sustainable Energy Systems. Green Energy and Technology* (pp. 247-266). London: Springer.
- [33] Ernst, B., Oakleaf, B., Ahlstrom, M. L., Lange, M., Moehrlen, C., Lange, B., Focken, U., Rohrig, K. (2007). Predicting the Wind. *IEEE Power and Energy Magazine*, 5 (6), 78-89. doi: <https://doi.org/10.1109/MPE.2007.906306>