



Ingeniería, investigación y tecnología

ISSN: 1405-7743

ISSN: 2594-0732

Facultad de Ingeniería, UNAM

Ibargüengoytia-González, Pablo Héctor; Reyes-Ballesteros, Alberto; Borunda-Pacheco, Mónica; García-López, Uriel Alejandro
Predicción de potencia eólica utilizando técnicas modernas de Inteligencia Artificial
Ingeniería, investigación y tecnología, vol. XIX, núm. 4, e033, 2018, Octubre-Diciembre
Facultad de Ingeniería, UNAM

DOI: <https://doi.org/10.22201/fi.25940732e.2018.19n4.033>

Disponible en: <https://www.redalyc.org/articulo.oa?id=40458316007>

- ▶ [Cómo citar el artículo](#)
- ▶ [Número completo](#)
- ▶ [Más información del artículo](#)
- ▶ [Página de la revista en redalyc.org](#)

UNAM  redalyc.org

Sistema de Información Científica Redalyc

Red de Revistas Científicas de América Latina y el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto



Predicción de potencia eólica utilizando técnicas modernas de Inteligencia Artificial Wind power forecasting using Artificial Intelligence tools

Ibargüengoytia-González Pablo Héctor

Instituto Nacional de Electricidad y Energías Limpias

Correo: pibar@ineel.mx

<https://orcid.org/0000-0001-8893-6708>

Reyes-Ballesteros Alberto

Instituto Nacional de Electricidad y Energías Limpias

Correo: areyes@ineel.mx

<https://orcid.org/0000-0002-8509-6974>

Borunda-Pacheco Mónica

CONACYT - Instituto Nacional de Electricidad y Energías Limpias

Correo: monica.borunda@ineel.mx

<https://orcid.org/0000-0003-4414-3815>

García-López Uriel Alejandro

Instituto Nacional de Electricidad y Energías Limpias

Correo: uriel.garcia@ineel.mx

<https://orcid.org/0000-0002-0643-2010>

Resumen

Existe una tendencia mundial por el uso de energías limpias en sustitución de combustibles fósiles, dado el constante incremento de la demanda energética y el interés por preservar el medio ambiente. De las energías renovables en el ámbito mundial, la energía eólica es la que ha tenido más crecimiento en los últimos años. Sin embargo, en el caso de México se tienen ciertas dificultades aún para extender su uso en ciertas regiones del territorio nacional. Una dificultad es la de conocer con suficiente anterioridad cuánta energía se dispondrá para inyectar a la red eléctrica. El presente trabajo describe el desarrollo de una tecnología de Inteligencia Artificial (IA) para el pronóstico de potencia eólica basado en información meteorológica de varios años. Específicamente, se realizó una investigación detallada sobre el uso potencial de las Redes Bayesianas para estas aplicaciones de pronóstico. Se identificó la necesidad de considerar el tiempo en el proceso de pronóstico y se realizó una propuesta novedosa basada en Redes Bayesianas Dinámicas (RBD). El sistema de pronóstico se probó con datos meteorológicos del centro regional de tecnología eólica (CERTe) del Instituto Nacional de Electricidad y Energías Limpias (INEEL) en Oaxaca, México. Se compararon los resultados con predicciones hechas con series de tiempo y se encontraron resultados satisfactorios confirmando que las Redes Bayesianas Dinámicas son una herramienta prometedora para la predicción de la potencia eólica.

Descriptores: Energía eólica, pronóstico de potencia, Inteligencia Artificial, Redes Bayesianas Dinámicas.

Abstract

There is a worldwide trend of using clean energy instead of fossil fuels, given the steady increase in energy demand and the interest in preserving the environment. Wind energy is the renewable energy which has grown the most at global level in recent years. However, there are still some difficulties to extend its use elsewhere in the country. One of these challenges is the difficulty of knowing in advance how much energy will be available to inject into the grid. This paper describes the development of a technique of Artificial Intelligence (AI) for wind power forecast using weather information for several years. Specifically, a detailed research on the potential use of Bayesian Networks for these forecasting applications was made. The need to consider the time in the forecasting process was identified and a new proposal of Dynamic Bayesian Networks (DBN) was performed. The forecast system with Dynamic Bayesian Networks was tested with data from the regional center for wind technology (CERTe) of the National Institute of Electricity and Clean Energies (INEEL) in Oaxaca, Mexico. Our results were satisfactorily compared with forecasting results from time series techniques indicating that DBN is a promising tool for wind power forecasting.

Keywords: Wind energy, power forecast, Artificial Intelligence, Dynamic Bayesian Networks.

INTRODUCCIÓN

El continuo incremento en la demanda energética y el hecho que las fuentes de energía fósil y nuclear son finitas, aunado a la necesidad de proteger el medio ambiente, hacen atractivo y necesario el aprovechamiento intensivo y extensivo de las fuentes renovables de energía. Dentro de las ventajas que presentan las energías renovables sobre las energías convencionales se encuentra el hecho que son inagotables y los costos de operación, al igual que la producción de contaminantes, particularmente las emisiones de CO₂, son muy bajos. Sin embargo, las principales desventajas de algunas fuentes renovables, como la solar y la eólica, son: su intermitencia o variabilidad y su difícil predictibilidad de la potencia disponible para ser aprovechada. Estas dos desventajas son muy importantes dado que en la red eléctrica debe existir un balance entre la electricidad consumida y su generación, con la finalidad de atender los códigos de operación de la red eléctrica. Por ejemplo, si la energía eléctrica producida por la energía eólica presenta una variabilidad en la potencia generada, se cuenta con energía no despachable y esta puede producir alteraciones en la calidad o en suministro.

La producción de energía eólica se afecta por parámetros atmosféricos, tales como la velocidad y dirección de viento, temperatura, humedad y presión, así como factores internos como la programación de mantenimientos y restricciones de diseño. Por un lado, es claro que el pronóstico de la generación eólica permite el control, la gestión, el mantenimiento y la planificación del despacho de energía eléctrica y por otro, el impacto de un buen despacho se traduce en ahorros económicos importantes y un mejor aprovechamiento de los recursos renovables para los proveedores de electricidad. Cuando la demanda de los usuarios y el despacho de los proveedores se estiman de manera sincronizada, los beneficios son aún mayores. Por ello, es deseable desarrollar métodos que permitan ajustar la oferta de un parque eólico basado en las condiciones del viento. Estas predicciones deben tener un horizonte de predicción tal, que ayude a calcular la producción de potencia y que mejore el ajuste a las curvas de demanda reales.

El pronóstico de energía eólica puede realizarse mediante métodos físicos y métodos estocásticos. Los métodos físicos están basados en consideraciones físicas del terreno, como rugosidad, orografía y obstáculos, así como de la atmósfera, donde modelan los perfiles locales del viento. En los modelos estocásticos la predicción se basa en el análisis de series de datos y se realizan mediante series de tiempo, técnicas estadísticas, y técnicas de inteligencia artificial.

En este trabajo se presenta un método de Inteligencia Artificial (IA) basado en las Redes Bayesianas Dinámicas (RBD) y el aprendizaje automático, el cual es una buena alternativa para el pronóstico eólico. Las RBD son una extensión de las Redes Bayesianas Estáticas o simplemente Redes Bayesianas (RB) cuyas principales características son:

- Permiten codificar conocimiento y experiencia humana, además ayudan a los usuarios al mantenimiento de sus modelos para incrementar su confianza en la exactitud de estos.
- Utilizan múltiples algoritmos de aprendizaje de modelos, con base en datos históricos para diferentes tipos de aplicaciones.
- Cuentan con poderosos mecanismos de inferencia para responder a consultas de información dada alguna evidencia.
- La salida de las redes bayesianas dinámicas son distribuciones de probabilidad y no un valor puntual de pronóstico.
- Permiten manejar información ruidosa o incompleta y son ideales para procesos intermitentes.

Este artículo desarrolla dos tipos de aportaciones originales: una académica y una tecnológica. La aportación académica corresponde al desarrollo de RBD para un pronóstico de corto plazo. Específicamente, se parte de la propuesta original de construcción de RBD (Murphy, 2002) y se extiende para utilizarse en aplicaciones de pronóstico cuando se cuenta con conjuntos de datos en forma de series de tiempo. En particular, en este caso se utiliza para el pronóstico de viento, y por lo tanto de potencia, en un horizonte de 5 horas. Esta propuesta se prueba mediante la predicción de velocidad y dirección del viento de la Ventosa en Oaxaca, México, usando datos históricos de dos años de una estación anemométrica en ese sitio. Por otro lado, la aportación tecnológica consiste en el desarrollo de una herramienta de software propietario (Ibargüengoytia, 2015) que permite el aprendizaje de redes Bayesianas dinámicas a partir de datos. Esta herramienta se emplea para realizar los experimentos. Finalmente, para evaluar la calidad del modelo se utiliza el error medio absoluto de la velocidad de viento. Los resultados se comparan con los obtenidos mediante métodos clásicos de pronóstico obteniendo resultados satisfactorios, ya que el error promedio es aceptable e inferior al utilizado por otras técnicas.

Lo que resta del artículo se estructura de la siguiente forma: en la siguiente sección se realiza una breve introducción al pronóstico de la potencia eólica. En la sec-

ción siguiente se presentan las herramientas de las Redes Bayesianas y las Redes Bayesianas Dinámicas que usamos en el pronóstico de la potencia eólica. Los experimentos y resultados se describen, analizan y evalúan en la sección siguiente. Finalmente, la última sección concluye el artículo y presenta el trabajo futuro.

PRONÓSTICO DE POTENCIA EÓLICA

El pronóstico de la potencia eólica corresponde a estimar la producción de energía eléctrica de un aerogenerador en un tiempo futuro. El pronóstico se puede realizar en diferentes escalas de tiempo. El pronóstico a corto plazo se realiza desde milisegundos a pocos minutos y se emplea para el control activo del aerogenerador. Los pronósticos realizados en la escala de horas o hasta 3 días, son de mediano plazo y son útiles para la gestión del sistema de energía y el comercio de la misma. Estas predicciones sirven para decidir el uso de las plantas convencionales (*unit commitment*) y para la optimización del despacho de estas plantas (*economic dispatch*). Los pronósticos realizados a 5-7 días son llamados de largo plazo y se emplean para planeación del mantenimiento.

La energía eólica es la energía cinética generada por las corrientes de grandes masas de aire, donde es bastante estable y predecible a escala anual, pero a escalas de tiempo menores depende de las condiciones meteorológicas. Las condiciones meteorológicas producen cambios en los movimientos de las masas de aire de manera directa en función de la radiación solar incidente, de la temperatura del medio ambiente, de la humedad relativa, de la presión atmosférica, de la altitud y de latitud. Estos cambios pueden presentar periodicidad en algunos días, meses, estaciones, temporadas o años. El viento puede tener velocidades pequeñas, desde 2 km/h correspondiendo a una ligera brisa, o hasta velocidades grandes, 120 km/h correspondiendo a un huracán, y puede tener una duración desde segundos hasta días.

La energía eólica se utiliza para producir electricidad mediante la conversión de la energía cinética a energía mecánica y posteriormente a energía eléctrica mediante el aerogenerador. De acuerdo con la ley de Betz el máximo de energía cinética del viento que un aerogenerador puede aprovechar es de 59.3% (Betz, 1966), sin embargo, los aerogeneradores comerciales alcanzan de 75% a 80% del límite de Betz (Burton, 2001). La potencia disponible en el viento a una velocidad v y que pasa a través de un área perpendicular A está dada por

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

donde ρ es la densidad del aire. La densidad del aire se asume constante en el rango de temperaturas de operación de Oaxaca. La Figura 1 corresponde a la curva de potencia de un aerogenerador y muestra la potencia eléctrica generada como función de la velocidad del viento. La curva de potencia caracteriza a un aerogenerador. La velocidad mínima a la que se empieza a generar potencia se llama velocidad de arranque y típicamente es de 3 m/s o 4 m/s. Conforme la velocidad aumenta la potencia también, y el aerogenerador opera a carga parcial hasta alcanzar la velocidad nominal, correspondiente a la potencia nominal. El aerogenerador está diseñado para producir esta potencia máxima a velocidades que se encuentran entre la velocidad nominal y la velocidad de parada, que corresponde a la velocidad máxima a la que el aerogenerador puede operar bajo condiciones seguras, siendo esta velocidad típicamente de 25 m/s.

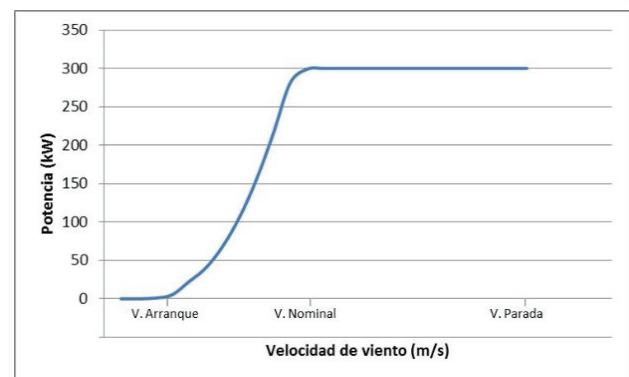


Figura 1. Curva de potencia de un aerogenerador

El pronóstico de energía eólica se puede realizar de forma directa o indirecta. En el primer caso, la estimación se realiza caracterizando la producción de energía a partir directamente de las variables de potencia eléctrica. En el segundo caso, se predice el comportamiento del viento mediante la estimación de variables meteorológicas y una asociación con la potencia eléctrica a través de curvas de potencia.

Los modelos empleados para la predicción se pueden clasificar en dos grandes grupos (Zhang, 2014): modelos físicos (Olaofe, 2016) y modelos estocásticos (Sideratos, 2007). Los métodos físicos están basados en consideraciones físicas del terreno, como rugosidad, orografía y obstáculos, y de la atmósfera, y modelan los perfiles locales del viento. Entre estos modelos se encuentran la predicción numérica del clima (NWP por sus siglas en inglés) (Olaofe, 2016), el análisis de imágenes del cielo (Chow, 2011), y el uso de modelos para los sistemas de generación.

En los modelos estocásticos la predicción se basa en el análisis de series de datos y se realiza mediante diversas técnicas:

- *Series de tiempo*. Utilizan datos históricos cuando los datos están disponibles. El pronóstico de una variable se hace con varios valores pasados de la misma variable.
- *Estadísticos*. Utilizan funciones estadísticas para estimar el valor de una variable dados los datos históricos de esta variable y otras variables relacionadas.
- *Inteligencia artificial (IA)*. Estos incluyen la construcción de modelos mediante algoritmos de aprendizaje automático, conocimiento experto o una mezcla de ambos.

Entre los principales métodos estadísticos se encuentran AR, ARMA, ARIMA (Wang, 2012). Por otro lado, los modelos actuales de pronóstico de viento basados en series de tiempo y modelos estadísticos son ALEASOFT, AEOLIS, CASANDRA, CENER, GARRAD HASSAN, METEOROLOGICA, METEOSIM o METEOTEMP (Enke, 1997). Estos se basan en las predicciones de los cambios atmosféricos provenientes de ciertos modelos numéricos y no tienen suficiente precisión para predecir la velocidad del viento para horizontes de más de 5 horas. Como una alternativa para resolver este problema, se encuentran los métodos que utilizan herramientas de IA, como por ejemplo, redes neuronales artificiales (ANN por sus siglas en inglés) (Jain, 1996), Redes Bayesianas (Pearl, 1988), lógica difusa y máquinas de soporte vectorial (SVM) (Vapnik, 1998), diseñados para abordar problemas complejos que los métodos convencionales no son capaces. Estos métodos “aprenden” de la relación entre la predicción y la serie de valores medidos. Normalmente estos métodos ofrecen mejores resultados en horizontes inferiores a las 2-4 horas, dependiendo del método seleccionado. Además, los métodos de IA comúnmente ofrecen mejores resultados que los métodos estadísticos.

Una técnica desarrollada por la comunidad de IA que ha probado ser eficiente para pronóstico es el enfoque de los Modelos Gráficos Probabilistas Dinámicos (MGPD). Usando este enfoque se logra enfrentar muchos de los retos listados. Sus características principales son:

1. Representa la dependencia condicional entre variables.
2. Es una técnica para razonar con procesos y ambientes inciertos.
3. Es capaz de representar conocimiento experto estructural y paramétrico.

4. Expresa sus resultados en la forma de distribuciones de probabilidad y no como valores puntuales.
5. Debido a su capacidad de representar independencia condicional, el enfoque de los MGPDs implícitamente excluye variables irrelevantes.

A pesar de estas características, y para apoyar la hipótesis de que con esta técnica se pueden obtener buenos resultados, se deben construir y evaluar diferentes modelos. Los principales MGPD son las redes Bayesianas y las redes de Markov.

En este trabajo utilizamos las Redes Bayesianas dinámicas (RBD), que se describen en la siguiente sección, para predecir la velocidad y dirección del viento mediante datos meteorológicos. Las RBD relacionan la velocidad y dirección del viento con la temperatura ambiente, la humedad relativa y la radiación solar para pronosticar la probabilidad de la velocidad y dirección del viento a un tiempo futuro. Posteriormente, se realiza un mapeo a la potencia eléctrica generada mediante la curva de potencia característica del aerogenerador en cuestión. A continuación, se describe brevemente la herramienta empleada para pronosticar la potencia eólica.

REDES BAYESIANAS Y REDES BAYESIANAS DINÁMICAS

El problema de la energía eólica es su fluctuación en la potencia y su variabilidad de disponibilidad. Es decir, es un problema con incertidumbre. De los métodos de IA idóneos para tratar con problemas con incertidumbre, las Redes Bayesianas (RB) han demostrado su utilidad en aplicaciones reales en general y en energías alternas en particular (Borunda, 2016). Las RB representan las relaciones de dependencia e independencia probabilista entre las variables de un proceso o sistema. Están basadas en el teorema de Bayes que relaciona la probabilidad condicional de un evento o hipótesis H dada una evidencia E , $P(H|E)$, en términos de la probabilidad condicional de la evidencia E dado H , $P(E|H)$,

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} \quad (2)$$

Las RB son métodos de IA porque permiten la representación del conocimiento de algún proceso en dos formas. Primero, la estructura de la red representa las dependencias e independencias entre variables. Segundo, los parámetros representan el conocimiento cuantitativo del proceso. Los parámetros se refieren a los términos $P(E|H)$ y $P(H)$. El término $P(E|H)$ es fácil de encontrar cuando se cuenta con datos históricos, por

ejemplo, de enfermedades y síntomas o de fallas en equipos y mediciones de efectos. Entonces $P(H/E)$ está dado por la ecuación (2).

Formalmente, una RB es un grafo acíclico dirigido, $G=(N,E)$, que permite la representación del conocimiento en alguna aplicación que maneja incertidumbre (Pearl, 1988; Sucar, 2015). Los nodos N representan un conjunto de variables aleatorias $X=\{X_1, X_2, \dots, X_n\}$. Los arcos E en la estructura representan la relación probabilista entre los nodos. Sea $Pa(X_i)$ el conjunto de nodos padres del nodo X_i . La estructura de la red Bayesiana corresponde a la distribución de probabilidad conjunta de la aplicación de la forma siguiente:

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa(X_i)) \quad (3)$$

donde $Pa(X_i)$ representa los nodos padres del nodo de la variable X_i . Esto implica, además, que para cada variable X_i en la RB, X_i es condicionalmente independiente de sus no-descendientes en la red, cuando se tiene la información de los padres $Pa(X_i)$. En suma, las RB representan las dependencias y las independencias entre las variables en una aplicación.

En cuanto a las dependencias, estas se cuantifican en forma de Tablas de Probabilidad Condicional (TPC) de los valores de un nodo hijo, dados los valores de sus padres $P(E|H)$. Se requiere proporcionar todas las TPC de los nodos hijos y los vectores de probabilidad a-priori $P(H)$.

Una vez capturado el conocimiento del proceso bajo análisis, se puede realizar el proceso de inferencia probabilista, es decir, se asigna un valor a los nodos conocidos con la evidencia e , y se calcula la probabilidad de alguna hipótesis $P(H|E=e)$. Esto equivale al cálculo de la probabilidad marginal de las variables desconocidas, dadas las variables conocidas, $P(X|e)$.

Las RB descritas hasta ahora realizan la inferencia de acuerdo con la evidencia medida en el modelo según la información a un instante de tiempo dado. Es decir, no hay ninguna dependencia temporal. Sin embargo, ciertas aplicaciones como el pronóstico de viento requieren modelar condiciones entre las variables meteorológicas actuales y las pasadas para calcular valores en el futuro. Para considerar el tiempo en los modelos de pronóstico Bayesianos, se desarrollan las Redes Bayesianas Dinámicas (RBD).

En las aplicaciones dinámicas, el universo de trabajo no es solo variables, sino series de tiempo de variables que van cambiando en el tiempo. El espacio está formado ahora por el conjunto $\mathbf{X}^{(t)} = \{X_1^{(t)}, X_2^{(t)}, \dots, X_n^{(t)}\}$ donde

$X_i^{(t)}$ representa a la variable X_i en el tiempo t . Entonces, el problema de pronóstico se convierte en $P(X_i^T | X_j^{(t)})$ donde X_i^T es la variable de interés al tiempo T , $i \neq j$.

Claramente, el espacio de combinaciones de variables en los diferentes instantes de tiempo representa un conjunto que puede ser muy complejo. Por lo tanto, se realizan las siguientes suposiciones:

1. Se consideran intervalos de tiempo, es decir, un tiempo discreto¹. Por lo tanto, $\mathbf{X}^t = \mathbf{X}^{(0)}, \mathbf{X}^{(1)}, \dots, \mathbf{X}^{(t)}$ y por consiguiente $P(\mathbf{X}^{(0:T)}) = \prod_{t=0}^{T-1} P(\mathbf{X}^{(t+1)} | \mathbf{X}^{(t)})$. Esto implica que algún valor en el futuro T depende de todos los valores del pasado y presente $(0:T)$.
2. El sistema es Markoviano. Esto es, $P(\mathbf{X}^{(0)}, \mathbf{X}^{(1)}, \dots, \mathbf{X}^{(T)}) = \prod_{t=0}^{T-1} P(\mathbf{X}^{(t+1)} | \mathbf{X}^{(t)})$. Es decir, el futuro es independiente del pasado dado el presente.
3. El sistema es estacionario. Esto es, $P(\mathbf{X}^{(t+1)} | \mathbf{X}^{(t)})$ es igual para toda t . Esto implica que el estado siguiente del proceso depende del estado presente, de la misma forma en cualquier parte de la muestra (un año a otro, las primaveras o los inviernos).

El procedimiento para la creación de la RBD desarrollada en este proyecto se inspira en la propuesta de RBD presentada en (Murphy, 2002). Este mecanismo, y la suposición de que el sistema es Markoviano, permiten crear una red Bayesiana de dos etapas que define $P(\mathbf{X}^{(t+1)} | \mathbf{X}^{(t)})$ para todo t en el proceso. Esta red es llamada red de transición. La Figura 2 muestra la red de transición aprendida en el caso de estudio. Cada nodo representa las variables meteorológicas involucradas en el análisis, donde la capa izquierda corresponde al tiempo t y la derecha al $t+1$. Nótese que todas las variables dependen de sí mismas al tiempo anterior y algunas como la temperatura (Temp_1) depende además de los valores anteriores de Humedad Relativa (HR) y Radiación Solar (RS) así como del valor actual de la radiación solar.

Dada la tercera suposición de que el sistema es estacionario, la RBD necesaria para el pronóstico en N unidades de tiempo en el futuro, se logra desenrollando la red de transición en $(N+1)$ capas o etapas. Por ejemplo, si se utilizan datos horarios y si se requiere pronosticar a 5 horas, la RBD se forma desenrollando la red de transición en seis capas. Se consideran seis capas dado que la primera capa corresponde a la capa de entrada y cada una de las cinco capas contiene el pronóstico de una hora en el futuro. La Figura 3 muestra la RBD resultante para el pronóstico de viento a un horizonte de 5 horas.

¹ La notación utilizada es como sigue. Las letras mayúsculas negritas representan conjuntos de variables, ejemplo \mathbf{X} . Letra mayúscula significa una variable, por ejemplo X .

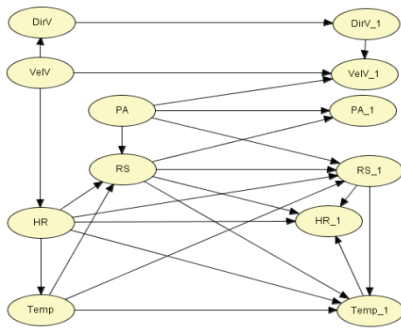


Figura 2. Red de transición del caso de estudio de la sección de experimentos

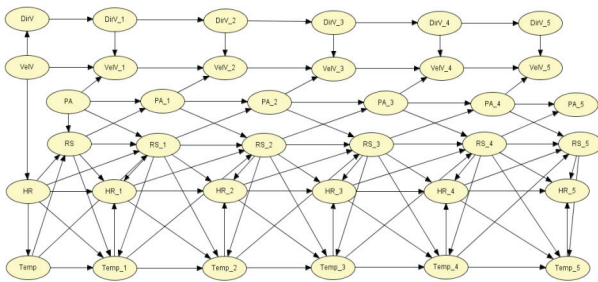


Figura 3. Red Bayesiana Dinámica resultante para el pronóstico a 5 horas

En resumen, el procedimiento de aprendizaje seguido en este proyecto para el pronóstico de potencia a 5 horas se resume en la siguiente metodología:

1. Separar la base de datos históricos en dos conjuntos. Datos para entrenar la RBD y datos para validar su funcionamiento. Nótese que los datos deberán ser series de tiempo, no solo un conjunto de registros.
2. En caso de que los datos originales tengan una base de tiempo menor a la base de tiempo requerida, tomar un promedio a los valores de las variables en las etapas requeridas.
3. Discretizar los valores continuos usando una partición uniforme.
4. Duplicar los datos de entrenamiento en dos columnas incluyendo los registros ($X^{(t)}$, $X^{(t+1)}$) en cada renglón. Utilizar un algoritmo de aprendizaje de redes Bayesianas para construir la red de transición. En este proyecto se utilizó el paquete Hugin (Anderesen, 1989) para construir la red de la Figura 2.
5. Desenrollar la red de transición en $(N+1)$ rebanadas de tiempo y formar la RBD como la de la Figura 3. Como se mencionó anteriormente, para un horizonte con N etapas en el futuro, se requieren $(N+1)$ capas.

6. Utilizar el algoritmo (*Expectation-Maximization*) EM (Lauritzen, 1995) para aprender los parámetros del modelo de la Figura 3, correspondientes a las matrices de probabilidad condicional de los nodos hijos y a los vectores de probabilidad a-priori de nodos raíz.

El tamaño de la RBD crece en capas de acuerdo con las etapas en el horizonte de pronóstico. Sin embargo, este método está limitado al pronóstico de pocas etapas en el futuro, ya que más de 10 ó 12 etapas resultan en un modelo Bayesiano impráctico por la cantidad de nodos en la inferencia (Cooper, 1990).

La inferencia en el modelo consiste en la asignación de valores en la capa de variables al tiempo t y la propagación de probabilidades en la red hasta la sexta capa. El resultado es una distribución de probabilidad posterior de todas las variables, incluyendo la velocidad de viento.

EXPERIMENTOS Y RESULTADOS

Los experimentos se realizaron en el centro regional de tecnología eólica (CERTe) del INEEL localizado en la Ventosa, Oaxaca, México. Su infraestructura está dimensionada para instalar hasta 5 MW de potencia eólica que pueden integrarse con turbinas de viento de diferentes capacidades y modelos.

El CERTe vende la energía eléctrica producida por la turbina eólica japonesa de 300 kW de la marca KOMAI que fue donada al INEEL por el Fondo Mundial para el Medio Ambiente (GEF por sus siglas en inglés) a través del Programa de las Naciones Unidas para el Desarrollo (PNUD).

Los datos históricos del viento y otras variables meteorológicas obtenidas de este centro, consisten en series de tiempo etiquetados con fecha y hora, durante más de dos años. La información recopilada incluye los siguientes datos: Temperatura ambiente (Temp), Humedad Relativa (HR), Radiación Solar (RS), Dirección De Viento (DirV) y Velocidad de Viento (VelV) de dos diferentes alturas sobre el nivel del terreno. El registro de los datos se tomó cada diez minutos. Se usaron datos del año 2012 y 2013 para el entrenamiento y datos de Enero y Febrero de 2014 para probar nuestro sistema. Los resultados preliminares se reportan en (Ibargüengoytia, 2014).

Como se mencionó anteriormente, el modelo aprendió usando datos meteorológicos del CERTe en el periodo de Enero de 2012 a Diciembre de 2013. El modelo se muestra en la Figura 3. Los experimentos se probaron con datos horarios de Enero a Febrero de 2014. Con

el fin de revisar el desempeño del sistema de predicción de acuerdo con las condiciones meteorológicas especificadas, se corrieron experimentos cargando condiciones actuales en horas específicas. Por ejemplo, se cargó evidencia de 0:00 horas (medianoche) y se comparó con el pronóstico de las 5:00 am. Asimismo, se analizaron los experimentos de las 12 a las 17 horas (medio-día). En estos dos periodos se observan importantes diferencias en la radiación solar y la temperatura.

Los experimentos se desarrollaron con la siguiente metodología:

1. Adquisición de datos históricos de variables meteorológicas de un sitio, incluyendo principalmente la velocidad y la dirección de viento.
2. Aprendizaje de los modelos de predicción siguiendo la metodología descrita en la sección anterior.
3. Alimentación de la RBD aprendida con valores en un instante dado usando datos históricos de pruebas. Las probabilidades se propagan y se obtiene la distribución de probabilidad posterior de la velocidad de viento en N capas al futuro. Esto se realiza mediante el paquete *Hugin* o cualquier otro paquete de manejo de modelos probabilistas.
4. Cálculo del valor numérico de la predicción y comparación con el valor real del archivo de datos de prueba. Este punto se detallará más adelante.
5. Cálculo de la diferencia y estimación del error de predicción.

Alternativamente, el entrenamiento de la RBD (paso 3) podrá realizarse con los valores actuales en alguna localidad para pronosticar N horas (o etapas) al futuro. Cabe mencionar que el error de pronóstico se calcula una vez concluidas las N etapas.

La Figura 4 muestra resultados del pronóstico de la velocidad del viento durante el mes de febrero. El eje

vertical representa la velocidad de viento en m/s . El eje horizontal representa las instancias de los experimentos, una por cada hora de cada día. Las líneas con etiquetas “Medido” y “Estimado” representan el valor medido de la velocidad del viento y el valor pronosticado, respectivamente. Como se aprecia hay horas en las que el pronóstico es muy cercano a los valores reales y otras donde la diferencia es más significativa.

La desviación del valor pronosticado con el valor medido se cuantifica a través del error. El error de instrumentistas se calcula mediante la siguiente ecuación:

$$E_{Inst} = \frac{(VelV_{real} - VelV_{forecast})}{(V_{max} - V_{min})} \times 100 \quad (4)$$

donde $VelV_{real}$ es la velocidad medida y $VelV_{forecast}$ es la pronosticada. Este mecanismo se usa por ingenieros instrumentistas cuando evalúan dispositivos. Este valor consiste en la diferencia del valor real y el pronosticado, dividido por el rango completo del instrumento. En este proyecto, asumimos $V_{max} = 25 m/s$, y $V_{min} = 0 m/s$.

La velocidad del viento es una variable muy difícil de pronosticar dada su incertidumbre y volatilidad natural. Los experimentos de 0 a 5 horas producen un error promedio de 8.21%, mientras los experimentos de las 12 a las 17 horas producen un error promedio de 5.76%. En la Figura 4, el error más alto está por encima de 19% mientras el más bajo es prácticamente 0. La mayoría de los errores son inferiores a 5%. Aunque en algunos casos pareciera un error grande, la literatura muestra qué sistemas de pronóstico de viento con este promedio de error son prometedores (Monteiro, 2009).

La literatura recomienda además de la medición del error en un solo punto del pronóstico, considerar la incertidumbre del pronóstico probabilístico (Monteiro, 2009; Zhang, 2014). Estas referencias establecen la nece-

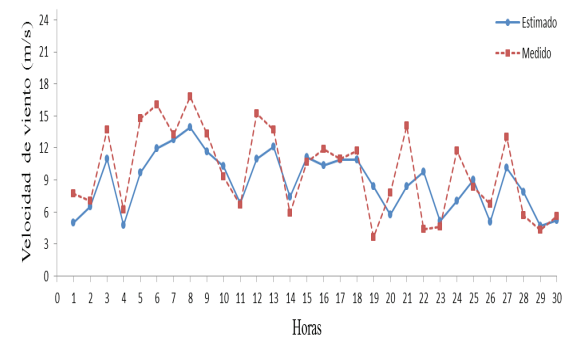
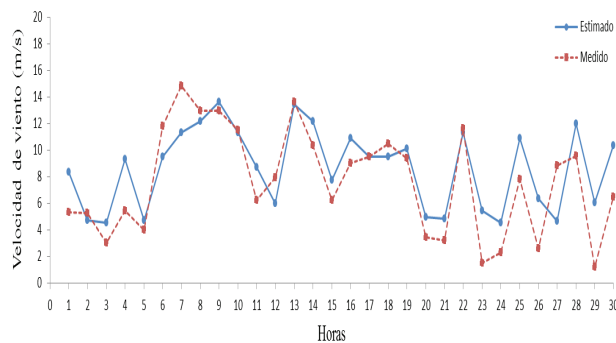


Figura 4. Gráfica parcial con los resultados de los experimentos de la velocidad del viento pronosticada de 0 a 5 horas y de 12 a 17 horas. Las líneas con las etiquetas “Medido” y “Estimado” representan el valor real y el valor pronosticado. El valor real y pronosticado se miden en m/s

sidad de calcular un modelo probabilístico, dado un modelo numérico de predicción meteorológica (NWP, por sus siglas en inglés). Ya que nuestro mecanismo de predicción es probabilista se obtiene una distribución de probabilidad de la velocidad del viento a 5 horas a futuro, dadas las condiciones meteorológicas en ese momento. Para calcular el NWP se utilizó el valor esperado del vector de probabilidad posterior, es decir, $V_{est} = \sum_n V_{elV_i} P_i$ donde V_{elV_i} es el valor central del intervalo i , y P_i es la probabilidad del intervalo.

La estimación de la incertidumbre del pronóstico de viento se calcula con el mecanismo de los cuantiles (Bremnes, 2004). Dada una distribución de probabilidad posterior de la velocidad del viento P_{t+k} donde t es el tiempo actual y k es el horizonte de pronóstico (número de rebanadas de tiempo por delante), el cuantil q_{t+k}^α con un parámetro $\alpha \in [0,1]$ se define como el valor de x dado que $prob(P_{t+k} < x) = \alpha$.

La Figura 5 muestra los resultados del mismo experimento que la Figura 4 con los dos cuantiles de 20% y 80%, formando un intervalo de confianza con probabilidad de 60%.

Este mecanismo establece que la generación de energía esperada para un horizonte dado es de entre 1 y 1.6 MW con 60% de probabilidad. Para completar la evaluación de los experimentos, la Tabla 1 muestra diferentes mediciones de errores (Osman, 2001) de los dos

experimentos descritos anteriormente. Como se observa, los experimentos realizados de las 12 a las 17 horas muestran errores menores. Por otro lado, otra medida para calcular el error en problemas de pronóstico es el error cuadrático medio (rms, por su sigla en inglés) correspondiente al error medio de la predicción al cuadrado, y se define como (Osman, 2001):

$$rms = \left[\frac{1}{n} \sum_{i=1}^n E_{Inst}^2 \right]^{\frac{1}{2}} \quad (5)$$

donde E_{Inst} es el error de instrumentistas definido en la ecuación 3.

Los errores reportados en la Tabla 1 se obtienen de los experimentos correspondientes a 30 casos de datos desde las 0 horas (o 12 horas), es decir, un mes. En cada experimento, un valor real se compara con el valor pronosticado. Los errores se calcularon usando las ecuaciones 3 y 5. Los números negativos en la primera fila representan sobre-estimación, ya que el valor estimado fue mayor que el valor real. La Tabla 1 compara el desempeño del pronosticador con diferentes métricas para los dos experimentos descritos. Se aprecia un desempeño mejor en el día que en la noche.

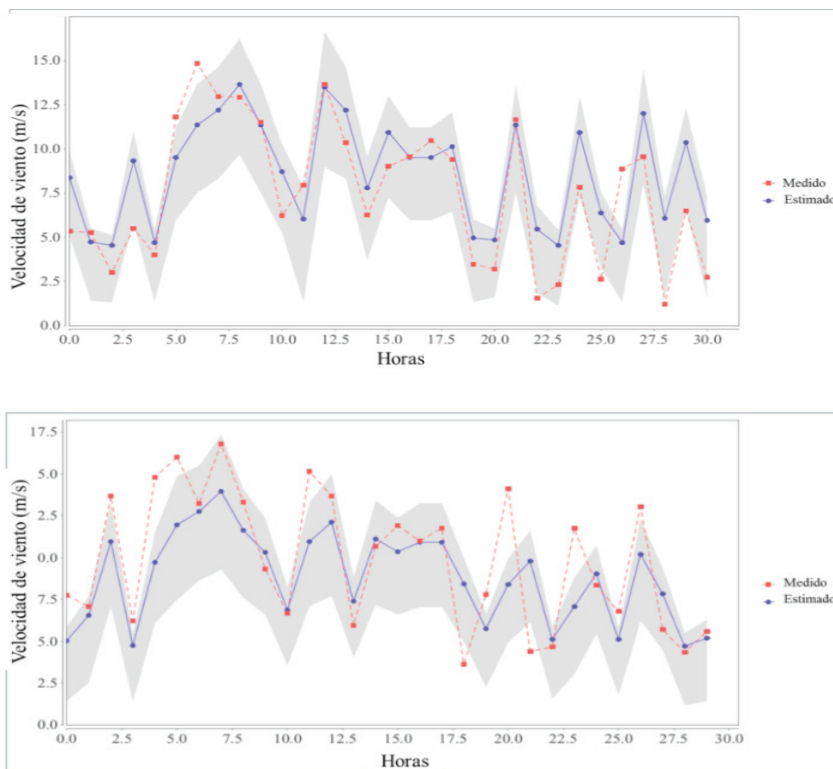


Figura 5. Resultados experimentales de 0 a 5 horas y 12 a 17 horas con incertidumbre definida. La región mostrada representa 60% de probabilidad. La gráfica roja se refiere a la velocidad medida, mientras que la azul representa la velocidad estimada

Con el fin de contrastar nuestros resultados de pronóstico con otros métodos tradicionales de series de tiempo estadísticas, la Tabla 2 muestra los resultados de estos métodos obtenidos a partir de un conjunto de experimentos para los mismos escenarios y los mismos conjuntos de datos.

La primera columna indica los modelos experimentados. AR es el modelo autorregresivo de orden 44. ARMA es un modelo autorregresivo (AR) de media móvil (MA) de orden 12 para AR y 30 para MA. Los dos últimos modelos son AR integrando MA con orden 6 y 27 para AR y MA, respectivamente (Box, 1994). La diferencia entre estos dos es que en el pre-procesamiento de datos, la media se resta de todos los valores para proporcionar invariabilidad respecto al tiempo (ajuste a la media). La cuarta y quinta columna son el error absoluto medio porcentual (MAPE, por sus siglas en inglés) y la precisión direccional (DA, por sus siglas en inglés). MAPE y DA miden la precisión y exactitud del modelo para predecir el futuro, respectivamente. Ambas métricas se expresan en porcentaje. Idealmente, los buenos modelos de predicción obtienen un bajo MAPE y un alto DA. Ambos errores, MAPE y DA, se calculan comparando el valor predicho contra el valor real. La Figura 6 muestra una pequeña sección de los resultados de los experimentos usando series de tiempos estadísticas.

Al comparar cualitativamente los resultados usando RBD (Figura 4) con los resultados usando métodos de series de tiempo (Figura 6) se puede apreciar que el hecho de utilizar múltiples variables en el pronóstico, en

vez del histórico de una variable, representa una ventaja en el desempeño. En la Figura 4 se aprecia a simple vista un mayor seguimiento de las curvas entre la medida y la pronosticada que las curvas de la Figura 6.

Velocidad de viento (m/s)

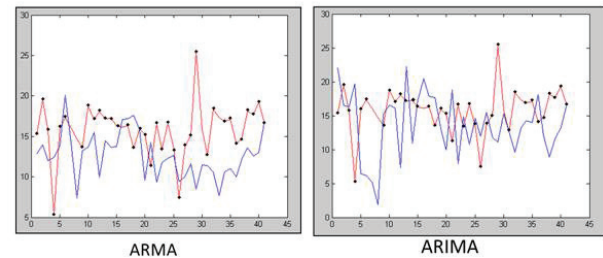


Figura 6. Gráfica parcial con los resultados de los experimentos usando los métodos de ARMA y ARIMA. Las líneas rojas representan el valor real y las líneas azules el valor pronosticado. El eje horizontal es tiempo

CONCLUSIONES Y TRABAJO FUTURO

El pronóstico de potencia eólica es un requisito indispensable para la expansión de este tipo de generación limpia. Las Redes Bayesianas son una técnica desarrollada para el manejo de sistemas inteligentes con incertidumbre. Este artículo presenta una aplicación novedosa de redes Bayesianas dinámicas para el pronóstico de potencia eólica. La contribución más importante de este trabajo radica en el desarrollo de modelos dinámicos especializados en el pronóstico de

Tabla 1. Resultados de error en los experimentos

Tipo de error	Experimento 0-5h	Experimento 12-17h
E_{inst} Porcentaje	-4.4	-2.3
E_{inst} Porcentaje absoluto	8.21	5.67
E_{inst} Mínimo	0.17	0.18
E_{inst} Máximo	19.4	17.36
Error cuadrático medio	9.84	7.28

Tabla 2. Resultados de errores en los experimentos usando métodos tradicionales

Modelo	AR Orden	MA Orden	MAPE	DA
AR	44	0	0.235171	45
ARMA	12	30	0.271023	52.5
ARIMA (a)	6	27	0.365057	27.5
ARIMA (b)	6	27	0.280259	35

(a) Con ajuste a la media

(b) Sin ajuste a la media

potencia de corto plazo y la metodología para aprender estos modelos. La innovación en nuestras RBD consiste en la correspondencia entre las suposiciones realizadas para el problema de pronóstico y la formación de la estructura de la RBD, en contraparte a la estructura clásica de las RBD propuestas en Murphy (2002).

En (Reyes, 2016), se presentó una metodología para construir modelos de predicción de potencia eólica usando redes Bayesianas dinámicas y un perceptrón multi-capas. Cada uno de estos dos modelos de predicción se evalúa y se compara para seleccionar aquel con el más alto rendimiento. En el caso del modelo Bayesiano, este se recalibra recursivamente para recuperar la precisión perdida por la discretización de variables. La novedad del método es que se comparan dos técnicas con variables de distinta naturaleza (discretas y continuas) y con diferentes fortalezas. De esta manera, se aprovecha mejor el poder de los aproximadores de funciones y de los métodos para manejo de incertidumbre.

En este artículo se presenta el desarrollo matemático de la formulación de nuestra propuesta de redes Bayesianas dinámicas. Resultados preliminares se presentaron en Iburgüengoytia (2014). Adicionalmente se extiende en este artículo una descripción detallada sobre la metodología y la teoría atrás de la construcción de nuestra propuesta original de redes Bayesianas. También se extiende en este artículo una descripción de los errores medidos y una discusión sobre el uso complementario de los modelos Bayesianos y las redes neuronales artificiales.

Se realizaron experimentos con los datos de la estación meteorológica del CERTE del INEEL en La Ventosa, Oaxaca y los resultados muestran que la Inteligencia Artificial tiene mucho que ofrecer en la solución de muchos problemas relacionados con las energías renovables. La IA ofrece mecanismos de aprendizaje y de representación de conocimiento que pueden traducirse en métodos más eficientes de solución de problemas.

Este trabajo de investigación es el preámbulo de un tema extenso. El trabajo futuro en este tema se enfocará en analizar si existen localidades cercanas que puedan aportar información útil para mejorar el pronóstico, es decir, se desarrollarán modelos dinámicos-espaciales que mejoren el rendimiento del pronóstico. Por otro lado, también se estudiará la condición de que el proceso de pronóstico sea Markoviano y se analizarán las consecuencias de esta restricción. Finalmente se examinarán las series de tiempo y se determinará si son estacionarias, y en caso de no serlo se definirá un modelo de RBD para cada etapa. Esta propuesta se comparará con otros modelos no lineales de predicción de series de tiempo.

AGRADECIMIENTOS

Este proyecto fue parcialmente apoyado por los proyectos 174919 y P12 del CEMIE- Eólico, ambos del Fondo de Sustentabilidad SENER-Conacyt, y el Instituto Nacional de Electricidad y Energías Limpias (INEEL). Mónica Borunda agradece al Conacyt por su posición de investigador cátedra número 71557, y al INEEL por su hospitalidad.

REFERENCIAS

- Andersen, S.K., Olesen, K.G., Jensen, F.V. y Jensen, F. (1989). Hugin-a shell for building Bayesian belief universes for expert systems. En: *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, 1080-1085.
- Anil, K.J., Jianchang, M. y Mohiuddin K.M. (1996). Artificial Neural Networks: A tutorial. *IEEE Computer*, (marzo de 1996), 31-44. <https://doi.org/10.1109/2.485891>
- Betz, A.N. (1996). *Introduction to the theory of flow machines*. En Randall D.G., Trans., Oxford: Pergamon Press.
- Borunda, M., Jaramillo, O.A., Reyes, A., e Iburgüengoytia, P.H. (2016). Bayesian networks in renewable energy systems: A bibliographical survey. *Renewable and Sustainable Energy Reviews*, 62, 32-45. DOI: 10.1016/j.rser.2016.04.030
- Box, G.E.P., Jenkins, G.M. y Reinsel, G.C. (1994). *Time-series analysis, forecasting and control*. Prentice Hall. Englewood Cliffs.
- Bremnes, J.B. (2004). Probabilistic wind power forecasts using local quantile regression. *Wind Energy*, 7(1), 47-54.
- Chow, C.W., Urquhart, B., Lave, M., Dominguez, A., Kleissl, J., Shields, J., y Washom, B. (2011). Intra-hour forecasting with a total sky imager at the UC San Diego solar energy testbed. *Solar Energy*, 85(11), 2881-2893.
- Cooper, G.F. (1990). The computational complexity of probabilistic inference using Bayesian networks. *Artificial Intelligence*, 42, 393-405. [https://doi.org/10.1016/0004-3702\(90\)90060-D](https://doi.org/10.1016/0004-3702(90)90060-D)
- Enke, W. y Spekat, A. (1997). Downscaling climate model outputs into local and regional weather elements by classification and regression. *Climate Research*, 8, 195-207. <https://doi.org/10.3354/cr008195>
- Hollingsworth, A. y Lonnberg, P. (1986) *The statistical structure of short-range forecast errors as determined from radiosonde data*. Part I: the wind field. John Wiley & Sons Ltd. <https://doi.org/10.1111/j.1600-0870.1986.tb00460.x>
- Iburgüengoytia, P.H., Reyes, A., Romero-Leon, I., Pech, D., García, U.A., y Borunda, M. (2015). A tool for learning dynamic Bayesian networks for forecasting. *Advances in artificial intelligence and its applications. Lecture notes in Computer Science*, 9414, 520-530. http://dx.doi.org/10.1007/978-3-319-27101-9_40
- Iburgüengoytia, P.H., Reyes, A., Romero-Leon, I., Pech, D., García, U.A., Sucar, E. y Morales, E. (2014) Wind power forecasting using dynamic Bayesian models. *Advances in soft computing*,

- Part II-MICAI 2014. *Lecture notes in Artificial Intelligence*, 8857, 184-197, Springer-Verlag.
- Lauritzen, S.L. (1995). The EM algorithm for graphical association models with missing data. *Computational Statistics & Data Analysis*, 19:191-201. [https://doi.org/10.1016/0167-9473\(93\)E0056-A](https://doi.org/10.1016/0167-9473(93)E0056-A)
- Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J. y Conzelmann, G. (2009). Wind power forecasting: State-of-the-art-2009. Technical Report ANL/DIS-10-1, Argonne National Laboratory, Decision and Information Sciences Division, Porto, Portugal.
- Murphy, K.P. (2002). *Dynamic Bayesian networks: representation, inference and learning* (Ph.d. thesis), University of California, Berkeley., Berkeley, CA, USA.
- Olaofe, Z.O. (2016). A surface-layer wind speed correction: A case-study of Darling station. *Renew. Energy*, 93, 228-244.
- Osman, E.A., Abdel-Wahhab, O.A. y Al-Marhoun, M.A. (2001). Prediction of oil PVT properties using neural networks. Society of Petroleum Engineers, SPE 68233, 14.
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: networks of plausible inference*. San Francisco, DA: Morgan Kaufmann Publishers.
- Reyes, A., Ibarguengoytia, P.H., Jijón, J.D., Guerrero, T., García, U. y Borunda, M. (2016). Wind power forecasting for the Villonaco wind farm using AI techniques. Advances in artificial intelligence and its applications, MICAI 2016. Lecture notes in computer science. Springer.
- Sideratos, G. y Hatzigiorgiou, N.D. (2007). An advanced statistical method for wind power forecasting. *Power Syst. IEEE Trans.*, 22(1), 258-265. <https://doi.org/10.1109/TPWRS.2006.889078>
- Sucar, L.E. (2015). *Probabilistic graphical models: Principles and applications*. Springer-Verlag, Londres.
- Vapnik, V.N. (1998). *Statistical learning theory*. Wiley Interscience.
- Zhang, Y., Wang, J., y Wang, X. (2014). Review on probabilistic forecasting of wind power generation. *Renew. Sustain. Energy Rev.*, 32, 255-270. <https://doi.org/10.1016/j.rser.2014.01.033>