

Reporte técnico

Modelo de estimación de potencia disponible en parques eólicos operando bajo restricción

Autores: Bruno López, Patricia Cobelli, Martín Draper

Diciembre 2020

Proyecto: Aporte de reserva rotante a través de parques eólicos.

Agencia Nacional de Investigación e Innovación

Fondo Sectorial de Energía, 2017

Código: FSE_1_2017_1_144504

Contenido

1	Introducción	3
2	Estimación de la velocidad efectiva.....	4
3	Modelo de parque eólico	5
3.1	Modelo de estelas.....	5
3.2	Modelo de intensidad de turbulencia.....	7
3.3	Superposición de estelas.....	8
4	Calibración del modelo de parque	8
5	Referencias.....	11

1 Introducción

El funcionamiento del modelo de estimación de la potencia disponible de un parque eólico operando bajo una restricción operativa se puede esquematizar en cinco etapas (ver Figuras 1 y 2). Este modelo está inspirado en la estrategia desarrollada en el trabajo (Göçmen et al. 2019). Este reporte describe el modelo desarrollado.

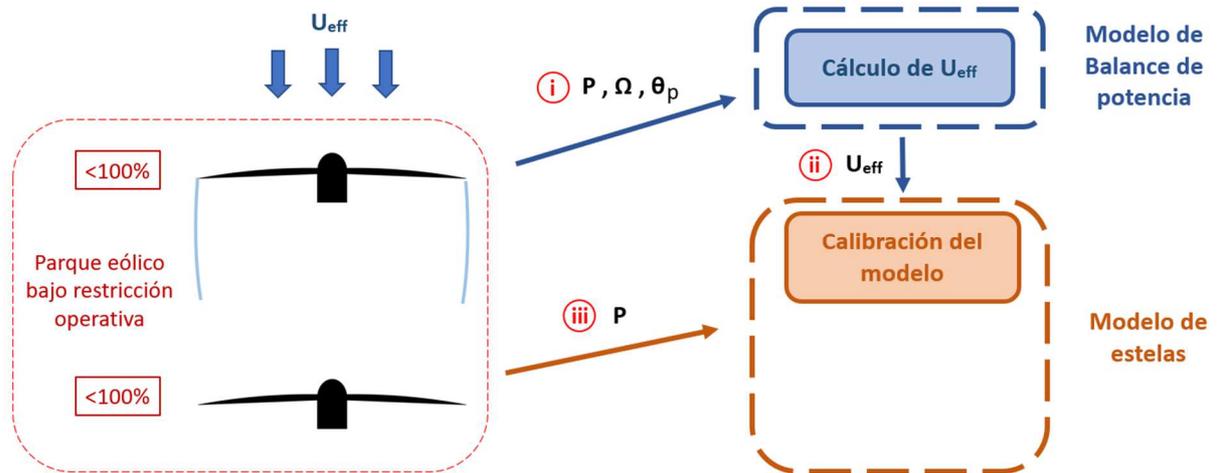


Figura 1. Esquema del modelo desarrollado: etapas i, ii y iii.

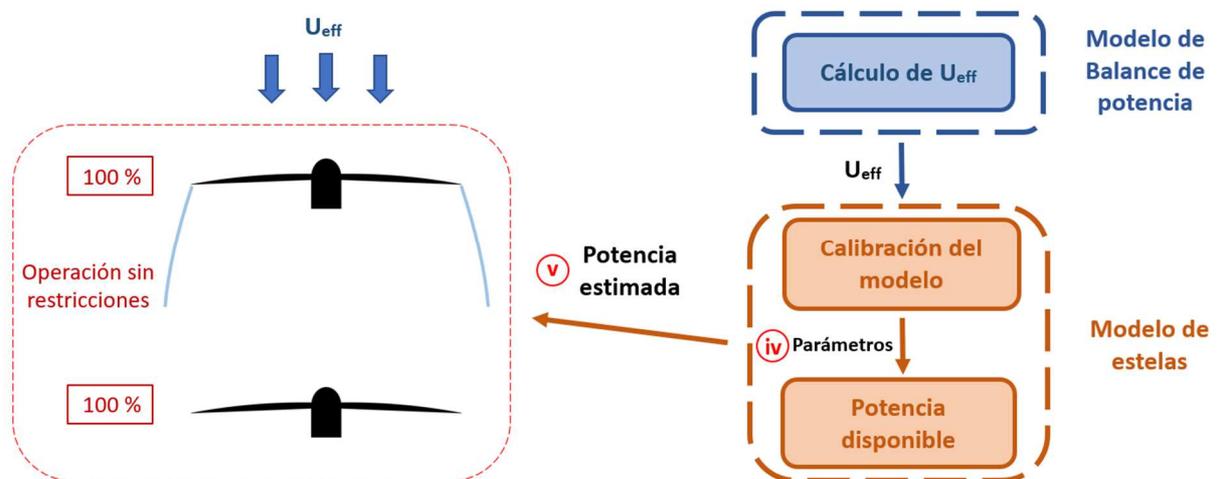


Figura 2. Esquema del modelo desarrollado: etapas iv y v.

El modelo consiste en primer lugar en determinar, a partir de la operación de los aerogeneradores ubicados corriente arriba y conociendo variables de su operación (potencia eléctrica, velocidad de giro, pitch), la velocidad de viento corriente arriba. Dicha velocidad constituye una velocidad efectiva en el rotor, pues se obtiene a partir de la repuesta integral del aerogenerador asociada a la potencia generada y las variables de operación que la afectan. A continuación, se requiere determinar la velocidad del viento en cada posición de aerogenerador a partir de un modelo de estelas y una estrategia de superposición, tomando la velocidad efectiva obtenida en la etapa anterior como velocidad de viento incidente. Con dicha velocidad, conociendo las características aerodinámicas y geométricas del rotor es posible estimar la potencia eléctrica generada. El modelo de estelas cuenta

con diversos parámetros. Dado que la operación bajo una restricción operativa es conocida, es posible calibrar el modelo de estelas en función de dicha información. A partir de la velocidad de viento efectiva y tomando el modelo de estelas calibrado a partir de la operación conocida, se determina usando nuevamente el modelo de estelas la potencia del parque eólico sin operar bajo la restricción operativa. Esto implica por un lado determinar la velocidad del viento en cada posición de aerogenerador y a partir de ésta calcular la potencia que genera.

2 Estimación de la velocidad efectiva

La velocidad del viento medida por los aerogeneradores con el anemómetro ubicado en su nacelle no representa correctamente la velocidad efectiva en su rotor (U_{eff}). Existen diversas formas de calcular esta velocidad. El artículo (Soltani et al. 2013) presenta seis formas de calcular la velocidad efectiva en el rotor de un aerogenerador a partir de las salidas típicas de los sensores de un aerogenerador. Dentro de éstas, el método que mejor estima la velocidad a altos valores de intensidad de turbulencia consiste en un balance de potencia al rotor del aerogenerador (PWB).

En el modelo de balance de potencia, se calcula la U_{eff} resolviendo la ecuación de potencia del rotor, ecuación (1).

$$\tau_r \frac{\omega_g}{N_g} = \frac{1}{2} \rho \pi R^2 U_{eff}^3 C_p(\beta, \lambda) \quad \text{Ec. (1)}$$

Donde:

- ω_g es la velocidad de giro del generador en rad/s. Esta se relaciona con la velocidad de giro del rotor (ω_r) según la ecuación (2), donde N_g es el ratio de la multiplicadora del aerogenerador.

$$\dot{\theta} = \omega_r - \frac{\omega_g}{N_g} \quad \text{Ec. (2)}$$

Se considera una transmisión perfecta donde $\dot{\theta}$ es nula, es decir, la torsión de la transmisión (θ) es constante. Con esto se obtiene una relación entre las velocidades:

$$\omega_r N_g = \omega_g \quad \text{Ec. (3)}$$

- τ_r es el torque del generador en N.m, calculado según la ecuación (4).

$$I_r \dot{\omega}_g = \frac{\tau_r}{N_g} - \tau_g - \tau_l \quad \text{Ec. (4)}$$

- I_r es la inercia del rotor en kg.m².
- τ_g es el torque del generador en N.m, medido por el aerogenerador.
- τ_l es la pérdida en el torque del generador en N.m, tomada como nula en el proyecto.
- $\dot{\omega}_g$ es la aceleración de giro del generador en rad/s². Si se considera este parámetro se tiene el modelo PWBD, si se toma como nulo se llama PWB. Dado que se tienen valores discretos de velocidad de giro del rotor, se calcula la aceleración de giro del rotor ($\dot{\omega}_r$) utilizando la ecuación (5) y se deriva la ecuación (3) para obtener $\dot{\omega}_g$.

$$\dot{\omega}_r(t) = \frac{\omega_r(t + \Delta t) - \omega_r(t - \Delta t)}{2\Delta t} \quad \text{Ec. (5)}$$

- ρ es la densidad del aire en kg/m^3 .
- R es el radio del rotor en m.
- $C_p(\beta, \lambda)$ es el coeficiente de potencia en función del ángulo de pitch (β) y de la relación entre la velocidad efectiva y la velocidad en punta de pala (ver ecuación (6)) donde ω_r es la velocidad de giro del rotor en rad/s .

$$\lambda = \frac{\omega_r R}{U_{eff}} \quad \text{Ec. (6)}$$

Para obtener el $C_p(\beta, \lambda)$ se utiliza el método BEM (Blade Element Momentum theory) para obtener una matriz de valores de C_p en función de una serie de valores de β y λ , a partir de la cual interpolar.

La elección de los rangos de β y λ contempla el rango de operación del aerogenerador. La determinación de la proximidad entre dos valores consecutivos es un compromiso entre velocidad de cálculo y precisión.

Para resolver la ecuación (1) se debe iterar dado que tiene U_{eff} al cubo y dentro del coeficiente de potencia. Para ello se utiliza el algoritmo Newton-Raphson. En este, se obtiene $U_{eff_{n+1}}$ a partir de U_{eff_n} de la forma detallada en la ecuación (7).

$$U_{eff_{n+1}} = U_{eff_n} - \frac{f(U_{eff_n})}{f'(U_{eff_n})} \quad \text{Ec. (7)}$$

3 Modelo de parque eólico

3.1 Modelo de estelas

En Bastankhah & Porté-Agel 2014 se introduce un nuevo modelo de estelas utilizando un perfil gaussiano. Este es un modelo que, además de ser más realista en el perfil de velocidad de la estela con respecto a modelos como el de Jensen (Jensen 1983, Katic et al. 1986), fue obtenido mediante la aplicación de ecuaciones de conservación de masa y cantidad de movimiento.

Los autores obtuvieron la siguiente expresión analítica resolviendo las ecuaciones mencionadas y asumiendo un perfil gaussiano y autosimilar en la estela:

$$\frac{\Delta U}{U_\infty} = \left(1 - \sqrt{1 - \frac{C_T}{8(\sigma/d_0)^2}} \right) \cdot \exp \left(-\frac{1}{2 \left(\frac{\sigma}{d_0} \right)^2} \cdot \left\{ \left(\frac{z - z_h}{d_0} \right)^2 + \left(\frac{y}{d_0} \right)^2 \right\} \right) \quad \text{Ec. (1)}$$

Donde:

- $\frac{\Delta U}{U_\infty}$ es el déficit de velocidad normalizado definido como:

$$\frac{\Delta U}{U_\infty} = \frac{U_\infty - U_W}{U_\infty} \quad \text{Ec. (2)}$$

U_∞ es la velocidad del flujo libre y U_W es la velocidad en la estela, ambos términos referidos en la componente del flujo.

- $\frac{\sigma}{d_0}$ se define como:

$$\frac{\sigma}{d_0} = k^* \frac{x}{d_0} + \varepsilon \quad \text{Ec. (3)}$$

d_0 es el diámetro del rotor del aerogenerador, x la distancia corriente abajo del aerogenerador, k^* está asociado a la tasa de crecimiento de la estela y ε es el término independiente de la relación de proporcionalidad.

Si bien se plantea la siguiente expresión teórica para ε :

$$\varepsilon = 0.25 \cdot \sqrt{\beta} \quad \text{Ec. (4)}$$

donde:

$$\beta = \frac{1}{2} \cdot \frac{1 + \sqrt{1 - C_T}}{\sqrt{1 - C_T}} \quad \text{Ec. (5)}$$

En la publicación se obtuvo una expresión corregida a partir de los resultados de la validación del modelo de estela, a saber:

$$\varepsilon = 0.2 \cdot \sqrt{\beta} \quad \text{Ec. (6)}$$

- Por último, $z - z_h$ es la distancia en la dirección vertical al eje del rotor, e y es la distancia horizontal al eje del rotor en la dirección transversal al flujo.

El modelo propuesto ha mostrado una concordancia aceptable con los resultados obtenidos mediante simulaciones en el marco de mecánica de los fluidos computacional usando el método Large Eddy Simulation (LES). Presenta una mejora sensible con respecto a los modelos comúnmente utilizados en paquetes comerciales como WAsP. Además, presenta la ventaja de tener un único parámetro a determinar mediante calibración, k^* .

En Niayifar & Porté-Agel 2016 se desarrolla un modelo para calcular la producción de un parque eólico a partir de este modelo de estelas. Los autores obtuvieron una expresión empírica para calcular la tasa de crecimiento de la estela, a partir de resultados obtenidos con simulaciones LES:

$$k^* = 0.3837 \cdot I + 0.003678 \quad \text{Ec. (7)}$$

Donde I es la intensidad de turbulencia del flujo inmediatamente corriente arriba del rotor. La expresión fue obtenida para un rango de I entre 6.5% y 15%, y refleja los resultados obtenidos por estudios recientes, que muestran una relación directamente proporcional entre la tasa de crecimiento de la estela y la intensidad de turbulencia del flujo medio.

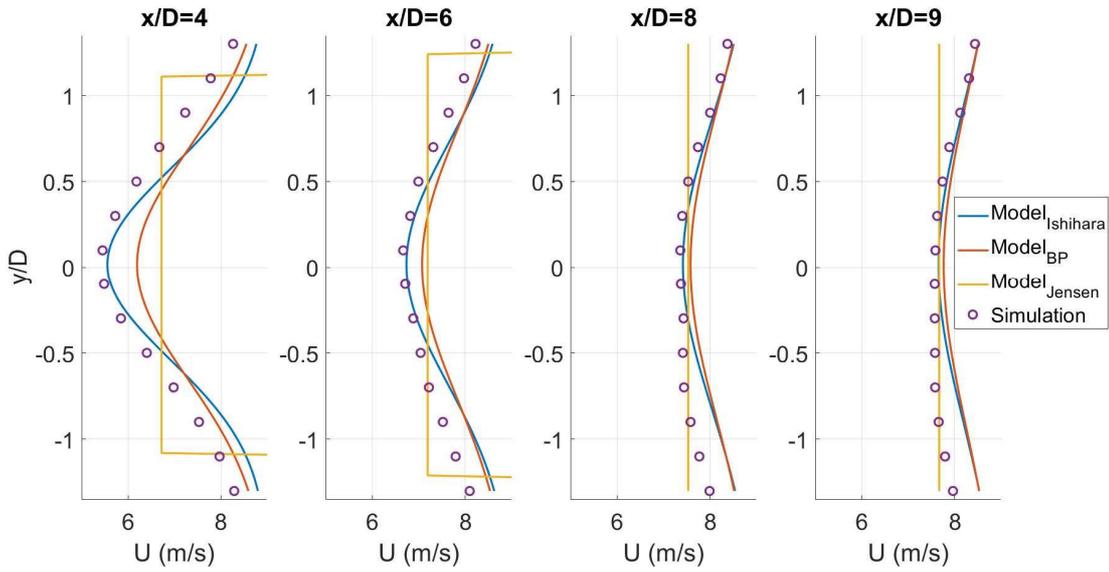


Figura 3. Promedio temporal de la componente longitudinal de la velocidad en función de la dirección transversal en la estela de un aerogenerador obtenido en una simulación de mecánica de los fluidos computacional con el código *caffa3d*, usando la estrategia Large Eddy Simulation – Actuator Line Model (Draper et al. 2018), y mediante modelos analíticos a diferente distancia del plano del rotor en la estela. Ishihara: modelo presentado en Ishihara & Qian 2018, BP: modelo presentado en Bastankhah & Porté-Agel, Jensen: modelo presentado en Jensen 1983, Katic et al. 1986.

3.2 Modelo de intensidad de turbulencia

El aumento de la intensidad de turbulencia, con respecto a la turbulencia ambiente, se calcula a partir de la siguiente expresión (Crespo & Hernández 1996):

$$I_+ = 0.73 \cdot a^{0.8325} \cdot I_0^{0.0325} \cdot (x/d)^{-0.32} \quad \text{Ec. (8)}$$

Donde I_0 es la intensidad de turbulencia ambiente y a es el factor de inducción. Esta ecuación es válida para los siguientes rangos de los parámetros:

$$5 < x/d_0 < 15, \quad 0.07 < I_0 < 0.14 \quad \text{y} \quad 0.1 < a < 0.4$$

Luego, la intensidad de turbulencia en la estela (I_{wake}) es determinada de la siguiente manera:

$$I_{wake} = \sqrt{I_+^2 + I_0^2} \quad \text{Ec. (9)}$$

Por último, en un parque con varios aerogeneradores interactuando a través de sus estelas, se propone la siguiente metodología para determinar el aumento de intensidad de turbulencia para el aerogenerador j como sigue:

$$I_{+,j} = \max\left(\frac{A_w^4}{\pi d_0^2} \cdot I_{+,kj}\right) \quad \text{Ec. (10)}$$

Donde A_w es el área de intersección entre la estela producida por el aerogenerador k y el área de barrido del rotor del aerogenerador j . Por su parte, $I_{+,kj}$ corresponde al incremento de intensidad de turbulencia producido por el aerogenerador k en la posición del aerogenerador j . Este método refleja

el hecho de que la intensidad de turbulencia de la estela que impacta sobre el aerogenerador j , es determinada mayormente por el aerogenerador que se encuentra inmediatamente corriente arriba.

3.3 Superposición de estelas

Para hallar la velocidad del viento que incide sobre un aerogenerador que se encuentra corriente abajo de múltiples aerogeneradores se necesita superponer las estelas que lo afectan. Es decir, no basta con tomar solamente la estela del aerogenerador más cercano, sino que se deben considerar métodos de superposición de estelas.

El método seleccionado consiste en una suma cuadrática de los déficits de velocidad de las estelas aguas arriba, como se muestra en la ecuación (11).

$$U_i = U_\infty - \sqrt{\sum_k (U_k - U_{ki})^2} \quad \text{Ec. (11)}$$

Donde:

- U_i es la velocidad que incide sobre el aerogenerador i .
- U_∞ es la velocidad de viento libre.
- k enumera a los aerogeneradores corriente arriba del aerogenerador i .
- U_k es la velocidad incidente sobre el aerogenerador k .
- U_{ki} sería la velocidad de la estela del aerogenerador k en la posición del aerogenerador i , si este no estuviera.

4 Calibración del modelo de parque

Para calibrar el modelo de parques eólicos se abordó la estrategia empleada por la herramienta numérica DREAM (Differential Evolution Adaptive Metropolis), desarrollada en los artículos (Vrugt et al. 2008, 2009). Esta herramienta se basa en la teoría de la inferencia bayesiana para determinar las distribuciones de probabilidad de los parámetros de ajuste de modelos matemáticos, a partir de mediciones realizadas sobre los procesos físicos que estos modelos representan. Las distribuciones se calculan a partir de muestreos aleatorios basados en la combinación de métodos como Markov Chain Monte Carlo y evolución diferencial.

El modelo DREAM fue implementado originalmente en Matlab por los autores a través de un paquete de herramientas, cuyos detalles se describen en Vrugt 2016, que permiten realizar calibraciones, optimizaciones y diversos análisis de post procesamiento. Para acotar la complejidad del modelo de calibración a implementar en el marco de este trabajo, se desarrolló un programa en Matlab que toma como base los algoritmos descritos en Vrugt 2016. Esto permite ir agregando y validando progresivamente las distintas técnicas, contenidas en DREAM, en un código propio.

A continuación, se describe la teoría de base en la formulación del DREAM. Se considera un proceso físico, que en este caso es la interacción de los aerogeneradores del parque y el recurso eólico, mediante el cual se transforma la energía cinética del viento en energía eléctrica. Este proceso físico es aproximado por un modelo matemático (modelo de parque) que permite inferir de manera aproximada la potencia producida por el parque. Analíticamente se puede escribir de la siguiente manera:

$$\tilde{P} = g(x) + \varepsilon$$

Donde \tilde{P} constituye un vector discreto de mediciones del proceso físico, que en este caso de estudio consiste en los valores medidos de la potencia global generada por el parque, y $g(x)$ es el modelo matemático de dicho proceso, que en este caso es el modelo de parque. Para simplificar se lo escribe como función únicamente de los parámetros, pero a modo general se deben considerar también las variables de entrada y los estados iniciales del modelo. Por último, x es el vector de parámetros del modelo y ε es el error total debido a errores en la medición y a errores inherentes al modelo matemático.

La teoría de inferencia bayesiana indica que, la distribución de los parámetros (x) una vez que se cuenta con mediciones de potencia del parque \tilde{P} , también conocida como probabilidad a posteriori $p(x|\tilde{P})$, se determina a partir de la siguiente relación:

$$p(x|\tilde{P}) = \frac{p(x) \cdot p(\tilde{P}|x)}{p(\tilde{P})}$$

Donde $p(x)$ es la probabilidad a priori de los parámetros, es decir la distribución estimada de los parámetros previo a la calibración con los datos de potencia medidos. $p(\tilde{P}|x)$ es la probabilidad condicional de que se observe \tilde{P} si la hipótesis x es verdadera. Esta probabilidad se conoce también como función de verosimilitud. Por último, $p(\tilde{P})$ es la probabilidad de observar los valores \tilde{P} y actúa como una constante de normalización, por lo que no afecta a las variables estadísticas de la distribución a posteriori. Por este motivo, a los efectos prácticos se utiliza la siguiente relación equivalente:

$$p(x|\tilde{P}) \propto p(x) \cdot p(\tilde{P}|x)$$

A partir de la relación anterior, se hace necesario definir la función de verosimilitud que mejor se adapta al proceso físico estudiado. Esta función está vinculada con el error entre los valores observados y el modelo matemático. El error se representa como un vector cuyos elementos son los errores observados en cada paso temporal de la serie:

$$e_t(x) = \tilde{p}_t - g_t(x)$$

Si se asume que estos errores tienen una distribución normal de media 0 y desviación estándar $\hat{\sigma}_t$, es decir:

$$e_t \sim N(0, \hat{\sigma}_t^2)$$

entonces la distribución de probabilidad de observar un elemento de la serie temporal \tilde{p}_t , dado el conjunto de parámetros x , es:

$$p(\tilde{p}_t|x) = \frac{1}{\sqrt{2\pi\hat{\sigma}_t^2}} \cdot \exp\left(-\frac{1}{2}\left(\frac{e_t(x)}{\hat{\sigma}_t}\right)^2\right)$$

Esta probabilidad se define como la función de verosimilitud. El gráfico de la siguiente figura intenta aclarar este concepto.

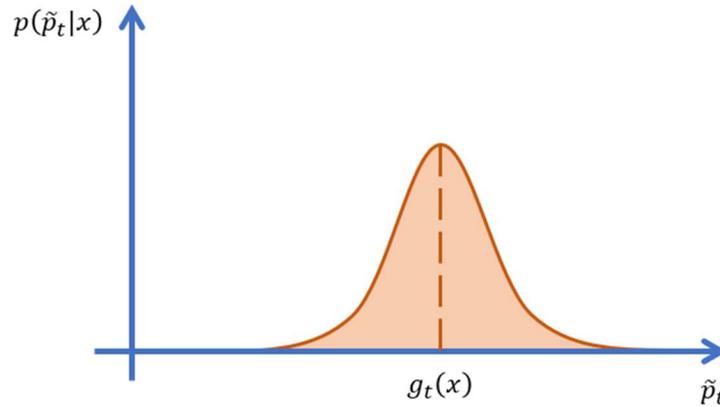


Figura 4. Función de verosimilitud.

Si además se asume que los valores de la serie temporal de errores no guardan correlación entre sí, la función de verosimilitud de la serie observada \tilde{P} y los parámetros x , se puede calcular como:

$$L(x|\tilde{P}, \hat{\sigma}^2) = \prod_{t=1}^n \frac{1}{\sqrt{2\pi\hat{\sigma}^2}} \cdot \exp\left(-\frac{1}{2}\left(\frac{e_t(x)}{\hat{\sigma}}\right)^2\right)$$

Donde $\hat{\sigma}^2$ es el vector que contiene las desviaciones estándar de los errores de cada paso temporal. El estimador de la desviación estándar se aproxima por la siguiente expresión:

$$s^2 = \frac{1}{n-1} \sum_{t=1}^n (e_t(x))^2$$

Por motivos de estabilidad numérica, se implementó la versión logarítmica de la función de verosimilitud.

El desarrollo anterior resume el enfoque de inferencia bayesiana para actualizar las estimaciones de los parámetros a partir de las mediciones realizadas sobre el proceso físico (o evidencia). De esta manera se procede a calibrar sucesivamente el modelo de parque partiendo de la distribución previa de los parámetros, la función de verosimilitud y la nueva serie de observaciones.

Debido a la complejidad de los modelos que impiden obtener expresiones analíticas de la distribución a posteriori, la determinación de esta distribución se realiza mediante métodos de muestreo aleatorios conocido como métodos Monte Carlo. En particular, el DREAM utiliza una adaptación del método Markov Chain Monte Carlo (MCMC). Este método consiste en generar una serie aleatoria recorriendo el espacio de posibles valores de los parámetros. La exploración se realiza a partir de la proposición de nuevos valores de la serie, que son aceptados o rechazados utilizando la distribución a posteriori obtenida por inferencia bayesiana.

La probabilidad de aceptación (p_{acc}) de la proposición X_p desde el estado actual X_i se determina a través de la siguiente regla (Random Walk Metropolis):

$$p_{acc} = \min\left(1, \frac{p(X_p)}{p(X_i)}\right)$$

donde $p(X)$ es la probabilidad a posteriori del vector de parámetros X , que contiene los parámetros x descritos en párrafos anteriores.

En DREAM este procedimiento de generación aleatoria es optimizado a partir de la utilización de un método de cadenas múltiples. Este método consiste en realizar un muestreo de la serie usando trayectorias en paralelo, lo que aumenta su eficiencia y robustez. Además, utiliza un algoritmo genético de evolución diferencial para aumentar la eficiencia en el proceso de proposición de nuevos candidatos de la serie. Por último, el DREAM incorpora un algoritmo de identificación de “outliers” en las trayectorias de muestreo para aumentar la velocidad de convergencia de la serie. Una vez que las trayectorias convergen, se combinan para generar la serie de valores que constituyen la población de parámetros. A partir de esta población obtenida, es posible inferir las variables estadísticas que caracterizan a la función de distribución a posteriori.

Los métodos descritos en esta sección fueron incorporados en el código de Matlab y utilizados para calibrar el modelo de parque. Una ventaja de esta metodología es que permite estimar la incertidumbre del modelo debida a la selección de los parámetros y con ello obtener intervalos de confianza para los valores de potencia disponible en parques operando bajo restricción operativa.

5 Referencias

- Bastankhah, M., & Porté-Agel, F. (2014). A new analytical model for wind-turbine wakes. *Renewable Energy*, 70, 116-123.
- Crespo, A., & Hernández, J. (1996). Turbulence characteristics in wind-turbine wakes. *Journal of wind engineering and industrial aerodynamics*, 61(1), 71-85.
- Göçmen, T., Giebel, G., Poulsen, N. K., & Sørensen, P. E. (2019). Possible power of down-regulated offshore wind power plants: The PossPOW algorithm. *Wind Energy*, 22(2), 205-218.
- Ishihara, T., & Qian, G. W. (2018). A new Gaussian-based analytical wake model for wind turbines considering ambient turbulence intensities and thrust coefficient effects. *Journal of Wind Engineering and Industrial Aerodynamics*, 177, 275-292.
- Jensen, N. O. (1983). A note on wind generator interaction.
- Katic, I., Højstrup, J., & Jensen, N. O. (1986). A simple model for cluster efficiency. In *European wind energy association conference and exhibition (Vol. 1, pp. 407-410)*.
- Niayifar, A., & Porté-Agel, F. (2016). Analytical modeling of wind farms: A new approach for power prediction. *Energies*, 9(9), 741.
- Soltani, M. N., Knudsen, T., Svenstrup, M., Wisniewski, R., Brath, P., Ortega, R., & Johnson, K. (2013). Estimation of rotor effective wind speed: A comparison. *IEEE Transactions on Control Systems Technology*, 21(4), 1155-1167.
- Vrugt, J. A., Ter Braak, C. J., Clark, M. P., Hyman, J. M., & Robinson, B. A. (2008). Treatment of input uncertainty in hydrologic modeling: Doing hydrology backward with Markov chain Monte Carlo simulation. *Water Resources Research*, 44(12).
- Vrugt, J. A., Ter Braak, C. J. F., Diks, C. G. H., Robinson, B. A., Hyman, J. M., & Higdon, D. (2009). Accelerating Markov chain Monte Carlo simulation by differential evolution with self-adaptive randomized subspace sampling. *International Journal of Nonlinear Sciences and Numerical Simulation*, 10(3), 273-290.
- Vrugt, J. A. (2016). Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation. *Environmental Modelling & Software*, 75, 273-316.