

Diagnosis of faults in a wind turbine using Analytical Redundancy Relations and an Artificial Neural Network

Pérez-Pérez, Esvan ^{*,**} López-Estrada, F. R. ^{*} Puig, Vicenç ^{**}

^{*} *Tecnológico Nacional de México/ Instituto Tecnológico de Tuxtla Gutiérrez, TURIX-Dynamics Diagnosis and Control Group, Carretera Panamericana Km 1080, Cp 29050, Tuxtla Gutiérrez, Chiapas (e-mail: frlopez@ittg.edu.mx).*

^{**} *Universitat Politècnica de Catalunya / Institut de Robòtica i Informàtica Industrial, CSIC-UPC./ Parc Tecnològic de Barcelona. C Llorens i Artigas 4-6, 08028, Barcelona, Spain.*

Abstract: This work proposes a method to diagnose faults in a wind turbine. The proposed approach combines the use of Analytical Redundancy Relationships (ARR) and an Artificial Neural Network (ANN). The ARR is used to generate a matrix of fault signatures through structural analysis, while the ANN is used to classify the detected faults. The results of the diagnostic system are presented using the measurements obtained from the model of a 4.8 [MW] wind turbine.

Keywords: Fault Diagnosis, Analytical Redundancy Relationships, Wind Turbines, Artificial Neural Networks, Data-based methods.

1. INTRODUCCIÓN

Debido al notable incremento de la producción de energía eléctrica mediante tecnología eólica resulta de gran importancia garantizar un funcionamiento correcto y continuo, de modo que se pueda sacar el máximo partido a estas máquinas de las cuales dependen grandes sectores de la población. Sin embargo, como todo mecanismo, los aerogeneradores están sujetos a sufrir fallas, lo cual provoca paros o baja eficiencia, provocando importantes pérdidas económicas (Hameed et al., 2009). Con el fin de evitar accidentes y pérdidas monetarias por falta de suministro de energía eléctrica resulta importante el desarrollo de metodologías para el diagnóstico de las fallas (Puig et al., 2010; Wang et al., 2019).

En los últimos años, se han desarrollado con éxito varios sistemas de detección de fallas para aerogeneradores. La mayoría de los enfoques propuestos se basan en el modelo físico del aerogenerador (Antoniadou et al., 2015; Artigao et al., 2018) y en función a estas, las técnicas de diagnóstico de fallas basado en modelos se aplican directamente (Dey et al., 2019). Sin embargo, el modelado de una turbina eólica es una tarea difícil en la práctica (Habibi et al., 2018), que todavía limita la aplicación de enfoques basados en modelos. Recientemente, los métodos basados en datos actualmente reciben considerable atención (Yousefian and Kamalasadán, 2017). A diferencia de los enfoques basados en modelos que requieren ecuaciones

dinámicas del proceso, los métodos basados en datos solo dependen de los datos del proceso medido. Varios métodos básicos basados en datos, como el análisis de componentes principales (PCA), PCA dinámico, análisis de componentes independientes, mínimos cuadrados parciales (Wang et al., 2018, 2016; Rezamand et al., 2019) y las Relaciones de Redundancia Analítica han sido bien desarrollados (Tornil-Sin et al., 2013; Sanchez et al., 2015; Villanueva and Verde, 2018). Las ARR se basan principalmente en analizar estructuralmente el sistema y obtener firmas de fallas directamente de los datos medidos por medio de residuos. Las ARR son conceptos importantes en el marco de detección de fallas basado en modelos; la idea básica de las ARR es generar una matriz de incidencia de fallas, donde cada relación genera un residuo el cual es sensible a una falla en particular. Si no se considera el ruido, el residuo generado debe ser distinto de cero cuando hay falla y cero cuando no hay falla. Sin embargo, en aplicaciones reales, el residuo generado debe evaluarse más a fondo, para tomar una decisión final correcta. En esta etapa se consideran métodos de aprendizaje automático, como Redes Neuronales Artificiales (RNA) (Ugalde et al., 2015; Leahy et al., 2018; Aguilar et al., 2020).

Con el fin de promover la detección de fallas y otras tecnologías relacionadas para aerogeneradores, Odgaard et al. (2013) desarrollaron un simulador de aerogenerador realista. En este marco, se han propuesto muchos diseños efectivos basados en el modelo físico de referencia

(Mokhtari and Belkheiri, 2018). Además, se estructura diferentes submodelos de los diferentes componentes del aerogenerador y se implementan diferentes escenarios de falla. Como resultado, se requieren técnicas de detección de fallas avanzadas más sofisticadas, tanto desde el punto de vista académico como práctico. Dado que es bastante difícil obtener un modelo matemático preciso de la turbina eólica, los enfoques basados en datos parecen más convenientes desde el punto de vista de la aplicación (Hossain et al., 2018). Por otro lado, visto desde la perspectiva de la teoría de control, un problema importante en el sistema de control de la turbina eólica es que la turbina eólica es impulsada por una perturbación, el viento. Sin embargo, la velocidad del viento se mide con un alto nivel de ruido, así como con un gran riesgo de desviación (Watson et al., 2019). Como la velocidad del viento influye directamente en el comportamiento dinámico del sistema, los generadores residuales robustos deben construirse directamente a partir de las mediciones de proceso disponibles, y lo más importante, estos generadores residuales deben ser sensibles a las fallas de salida e insensibles a las perturbaciones con el fin de evitar falsas alarmas.

Para este propósito, en este trabajo se propone un esquema robusto de detección de fallas basado en datos para aerogeneradores. En la Figura 1 se muestra un esquema de detección de fallas, que contiene dos pasos: (a) generación residual por ARR y (b) análisis residual mediante una RNA que realiza la clasificación de las fallas. En el primer paso, se genera una matriz de firmas de fallas, donde cada residuo obtenido es sensible a una falla en particular. En el segundo paso, se proporciona un enfoque de RNA (Patternet) para clasificación de las fallas, teniendo como entradas los residuos obtenidos de las ARR y las fallas son los valores objetivos de la RNA.

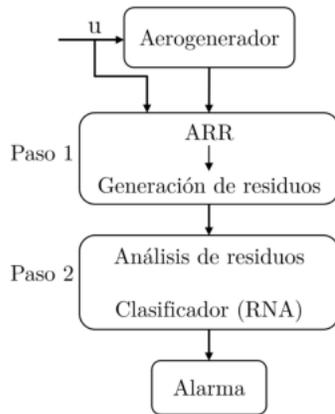


Figura 1. Diagrama de bloques de la generación de residuos por ARR y la clasificación de las fallas

Este artículo está organizado de la siguiente manera: La Sección 2 presenta el modelo de referencia de la turbina eólica y los escenarios de falla. La Sección 3 se desarrolla el esquema de diagnóstico de fallas basado en ARR y RNA. Los resultados del método es presentado en la Sección 4.

Finalmente, el documento termina con la conclusión en la Sección 5.

2. MODELO DEL AEROGENERADOR

En este trabajo se considera un modelo de referencia propuesto en Odgaard et al. (2013) mediante Simulink. El modelo del aerogenerador contiene varios submodelos: palas y sistema de pitch, caja de transmisión, generador-convertidor y controlador (ver Figura 2). El modelo de referencia simula un aerogenerador de eje horizontal de tres palas. La entrada al sistema es la velocidad del viento con turbulencias. El modelo de referencia es complejo y realista, diseñado especialmente para probar diferentes esquemas de detección y aislamiento de fallas en aerogeneradores.

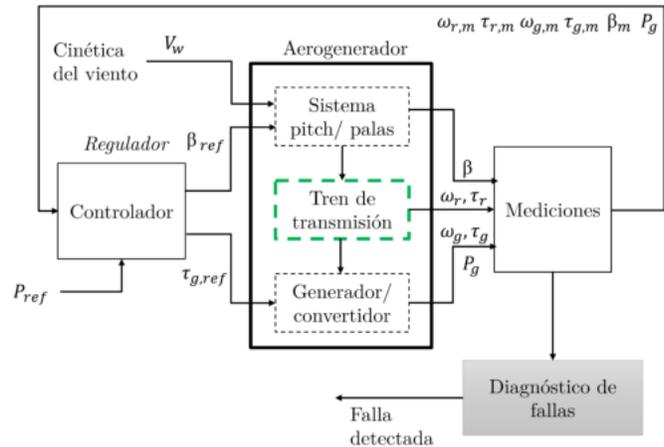


Figura 2. Submodelos del aerogenerador

2.1 Modelo aerodinámico

Este modelo matemático no lineal, construido a partir de principios físicos fundamentales, permite calcular el momento de fuerza aerodinámico sobre las palas que hacen girar al rotor capturando una potencia aerodinámica dada por la expresión:

$$\tau_r(t) = \frac{1}{2} \rho \pi R^3 C_q(\lambda(t), \beta(t)) v_w^2(t) \quad (1)$$

donde ρ es la densidad del aire, R es el radio del rotor o longitud de las palas, $C_q(\lambda(t), \beta_r(t))$ es el coeficiente del momento de fuerza que depende del ángulo de paso de las palas $\beta_r(t)$ y $\lambda(t)$ es la relación de velocidad punta.

2.2 Modelo del sistema pitch

El sistema pitch está modelado como una función de transferencia de bucle cerrado entre el ángulo de paso β y su referencia β_r . Es un sistema de servo pistón que

se puede modelar por una función de transferencia de segundo orden

$$\frac{\beta(s)}{\beta_r(s)} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (2)$$

donde ζ es el factor de amortiguamiento y ω_n es la frecuencia natural. Esta función de transferencia se asocia con cada uno de los tres sistemas de paso. En ausencia de fallos de actuador, el factor de amortiguación (ζ) y la frecuencia natural (ω_n) se suponen iguales en las tres palas a los valores nominales: $\zeta=0.6$ y $\omega_n=1.11$ [rad/s] respectivamente.

2.3 Modelo del generador y convertidor

La dinámica del convertidor puede ser modelada por una función de transferencia de primer orden

$$\frac{\tau_g(s)}{\tau_{g,r}(s)} = \frac{\alpha_{gc}}{s + \alpha_{gc}} \quad (3)$$

La potencia producida por el generador está dada por:

$$P_g(t) = \eta_g \omega_g(t) \tau_g(t) \quad (4)$$

La eficiencia del generador en el modelo de referencia es $\eta_g=0.98$.

2.4 Modelo del tren de transmisión

Un modelado de tren de transmisión de dos masas puede ser representado por el siguiente sistema de ecuaciones:

$$\dot{\omega}_r(t) = -\frac{(B_{dt} + B_r)}{J_r} \omega_r(t) + \frac{B_{dt}}{N_g J_r} \omega_g(t) - \frac{K_{dt}}{J_r} \theta_{\Delta}(t) + \frac{\tau_r(t)}{J_r} \quad (5)$$

$$\dot{\omega}_g(t) = \frac{\eta_{dt} B_{dt}}{N_g J_g} \omega_r(t) - \left(\frac{\eta_{dt} B_{dt}}{N_g^2 J_g} + \frac{B_g}{J_g} \right) \omega_g(t) + \frac{\eta_{dt} K_{dt}}{N_g J_g} \theta_{\Delta}(t) - \frac{\tau_g(t)}{J_g} \quad (6)$$

$$\dot{\theta}_{\Delta}(t) = \omega_r(t) - \frac{\omega_g(t)}{N_g} \quad (7)$$

donde

- J_r, J_g : momento de inercia del eje de baja y alta velocidad respectivamente.
- K_{dt} : rigidez de torsión de la transmisión.
- B_{dt} : coeficiente de amortiguación de torsión de la transmisión.
- B_r, B_g : fricción viscosa del eje de baja y alta velocidad respectivamente.
- N_g : relación de transmisión.
- η_{dt} : eficiencia del tren de transmisión.
- $\theta_{\Delta}(t)$: ángulo de torsión del tren de transmisión.

2.5 Parámetros del modelo de referencia

La Tabla 1 presenta los parámetros del modelo de referencia del aerogenerador.

Tabla 1. Parámetros del modelo de referencia

Símbolo	Significado	Valores
N_g	Relación de transmisión	95
J_r	Momento de inercia del motor	55×10^6 [kg.m ²]
K_{dt}	Rigidez del momento de fuerza del tren de transmisión	2.7×10^9 [Nm/rad]
ρ	Densidad del aire	1.225 [kg/m ³]
ζ	Relación de amortiguación	0.6
η_{dt}	Eficiencia de caja de transmisión	0.97
R	Radio del rotor	57.5 [m]
B_{dt}	Coefficiente de amortiguación del momento de fuerza	45.6 [Nms/rad]
B_r	Fricción viscosa del eje de baja velocidad	775.49 [Nms/rad]
B_g	Fricción viscosa del eje de alta velocidad	7.11 [Nms/rad]
J_g	Momento de inercia del generador	390 [kg/m ²]

2.6 Escenarios de fallas

En este modelo de referencia se cubren diferentes tipos de posibles fallas en el aerogenerador, las cuales están listadas en la Tabla 2. Estas fallas tienen diferentes grados de severidad, algunas son muy serias y deberían resultar en un cierre rápido y seguro del aerogenerador; otras fallas son menos severas donde el controlador actúa para manejar estas fallas.

Tabla 2. Fallas presentes en las simulaciones

Nomenclatura	Descripción
Falla 1	Valor fijo en la posición Pitch 1 sensor 1
Falla 2	Error de escala en la posición Pitch 2 sensor 2
Falla 3	Valor fijo en la posición Pitch 3 sensor 1
Falla 4	Valor fijo en el sensor 1 de velocidad del rotor
Falla 5	Error de escala en el sensor 2 de velocidad del rotor
Falla 6	Actuador de paso 2, cambió la respuesta del sistema pitch
Falla 7	Cambio en respuesta del actuador del sistema pitch 3, baja presión
Falla 8	Offset en control del momento de fuerza del convertidor

3. ESQUEMA DE DIAGNÓSTICO DE FALLAS

3.1 Relaciones de redundancia analítica

Del modelo de esos subsistemas presentados en el modelo de referencia, el análisis estructural propuesto por Staroswiecki, presentado en (Yang et al., 2019), puede ser aplicado con SaTool (Quiñones-Grueiro et al., 2019). Las variables consideradas conocidas son las salidas medidas ($V_w, \omega_r, \omega_g, \beta_1, \beta_2, \beta_3, \tau_g, P_g$) y entradas controladas (τ_{gr}, β_{gr}). τ_r se estima a partir de la velocidad del viento V_w usando la ecuación (1). De acuerdo a este enfoque, la estructura del modelo es un dígrafo cuya matriz de

incidencia representa los enlaces entre las variables (conocido y desconocido) y las ecuaciones elementales del modelo. Desde la estructura del modelo, reemplazando las variables desconocidas por las conocidas, un conjunto de relaciones de redundancia se pueden encontrar (ver Tabla 3) en Blesa et al. (2011):

Tabla 3. Conjunto de relaciones de redundancia obtenidas del análisis estructural

	ω_r	ω_g	β_1	β_2	β_3	β_r	τ_r	τ_{gr}	τ_g	P_g
$\hat{\omega}_r$	x						x		x	
$\hat{\omega}_g$		x					x		x	
$\hat{\beta}_1$			x			x				
$\hat{\beta}_2$				x		x				
$\hat{\beta}_3$					x	x				
$\hat{\tau}_g$								x	x	
\hat{P}_g		x							x	x

A partir del conjunto de relaciones de redundancia derivadas del análisis estructural y considerando el conjunto de sensores redundantes ($\omega_{r_m2}, \omega_{g_m2}, \beta_{1_m2}, \beta_{3_m2}$), se puede generar el siguiente conjunto de residuos.

$$r_1 = \omega_{r_m1} - \omega_{r_m2} \quad (8)$$

$$r_2 = \omega_{r_m2} - \hat{\omega}_r(\omega_{r_m2}, \tau_r, \tau_{g_m}) \quad (9)$$

$$r_3 = \omega_{g_m1} - \omega_{g_m2} \quad (10)$$

$$r_4 = \omega_{g_m2} - \hat{\omega}_g(\omega_{g_m2}, \tau_r, \tau_{g_m}) \quad (11)$$

$$r_5 = \beta_{1_m1} - \beta_{1_m2} \quad (12)$$

$$r_6 = \beta_{1_m2} - \hat{\beta}_1(\beta_{1_m2}, \beta_r) \quad (13)$$

$$r_7 = \beta_{2_m1} - \beta_{2_m2} \quad (14)$$

$$r_8 = \beta_{2_m2} - \hat{\beta}_2(\beta_{2_m2}, \beta_r) \quad (15)$$

$$r_9 = \beta_{3_m1} - \beta_{3_m2} \quad (16)$$

$$r_{10} = \beta_{3_m2} - \hat{\beta}_3(\beta_{3_m2}, \beta_r) \quad (17)$$

$$r_{11} = \tau_{g_m} - \hat{\tau}_g(\tau_{g_m}, \tau_{gr}) \quad (18)$$

$$r_{12} = P_{g_m} - \hat{P}_g(\omega_{g_m2}, \tau_{g_m}) \quad (19)$$

Analizando el efecto de cada una de las fallas propuestas en el modelo de referencia en los residuos anteriores utilizando el análisis de sensibilidad a fallas (Dey et al., 2019), se obtiene la matriz de firma de fallas presentada en la Tabla 4. Esta tabla destaca también aquellos residuos que presentan una mayor sensibilidad a la falla con respecto a una falla dada. Se observa que los residuos 2 y 4 contienen una "xx" ya tienen poca sensibilidad hacia las fallas. Esto se debe al alto nivel de ruido presente en el sensor de viento utilizado en la estimación de τ_r . Se descarta entonces el uso de estos residuos para la etapa de evaluación.

3.2 Análisis de residuos por la RNA

Después de generar los residuos, se procede a entrenar una RNA para clasificación de las fallas. Se considera importante establecer el aprendizaje de la red es supervisada y entrenada fuera de línea. Según la matriz de incidencias, cada residuo es sensible a un determinado

Tabla 4. Matriz de firma teórica: "xx" denota que un residuo es altamente sensible a una falla.

	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8
r_1				xx				
r_2	x	x	x		x	x	x	x
r_3					xx			
r_4	x	x	x		x	x	x	x
r_5	xx							
r_6	x							
r_7		xx						
r_8		x				xx		
r_9			xx					
r_{10}			x				xx	
r_{11}								xx
r_{12}					xx			

tipo de falla. Entonces, se etiquetan cada residuo a una clase (falla) para el entrenamiento de la RNA. Lo que se espera después del entrenamiento es que la red clasifique una falla de acuerdo a los datos de los residuos.

Preparación del conjunto de datos: Primero se establece que el conjunto de datos conformados por los 9 residuos que son más sensibles a las fallas, serán las entradas a la RNA. Los 8 tipos de fallas serán los valores objetivos (targets), a las cuales la RNA debe aprender a identificar. El conjunto de datos se divide en 3 subconjuntos: Un 70 % para entrenamiento, mientras que los conjuntos de datos de validación y prueba se establecen cada uno al 15 % de los datos originales. Con esta configuración, los datos de entrada y los datos de salida se dividirán aleatoriamente en tres conjuntos de la siguiente manera:

- El 70 % se utiliza para entrenamiento.
- El 15 % se utiliza para validar que la red se está generalizando y para detener el entrenamiento antes de sobreajustar los datos.
- El último 15 % se utiliza como una prueba de generalización de red.

Selección de la RNA: Para seleccionar la red más adecuada, se mide el rendimiento de la red neuronal por medio la matriz de confusión. Para esta sección, el nivel de precisión se obtendrá por el porcentaje de patrones correctamente clasificados.

$$CCR = \frac{tp + tn}{tp + tn + fp + fn} = \frac{1}{N} \sum_{i=1}^Q n_{ii} \quad (20)$$

donde:

- tp (true positive en inglés): es el número de elementos pertenecientes a la clase positiva que el clasificador ha predicho como positivos
- fn (false negative en inglés): es el número de elementos de la clase positiva que han sido clasificados como negativos.
- fp (false positive en inglés): es el número de elementos pertenecientes a la clase negativa que han sido clasificados como positivos.

- *tn* (true negative en inglés): es el número de elementos de la clase negativa que han sido predichos como negativos.

Se hicieron pruebas con varias configuraciones para la RNA, variando las capas ocultas y el número de neuronas. En la Tabla 5, se observa que hay una tendencia de mejora al incrementar las neuronas y las capas ocultas.

Tabla 5. Rendimiento de CCR de las diferentes estructuras probadas

Arquitectura de RNA	Epocas	CCR General [%]
9, 10, 10, 8, 8	25	53.8
9, 15, 10, 8, 8	28	55.2
9, 30, 15, 8, 8	26	57.1
9, 60, 30, 8, 8	30	63.8
9, 70, 40, 8, 8	32	67.4
9, 90, 60, 8, 8	37	72.7
9, 110, 80, 8, 8	48	78.5
9, 150, 100, 8, 8	76	93.9
9, 170, 120, 8, 8	76	97.9

4. RESULTADOS

La RNA que mejor desempeño obtuvo fue con CCR del 97.9% de precisión. La RNA es una Feedforward Back-propagation, con 9 neuronas de entradas, en las 3 capas ocultas se usaron 170,120 y 8 neuronas respectivamente y a la salida 8 neuronas como clases objetivo de la RNA. En la Figura 3 se observa la arquitectura completa de la RNA, mejor conocida como Patternet (Lucas et al., 2018). Las funciones de activación fueron logsig, logsig y softmax; estas funciones son las mas comunes y mas utilizadas para tareas de clasificación, según (Yogitha and Mathivanan, 2018).

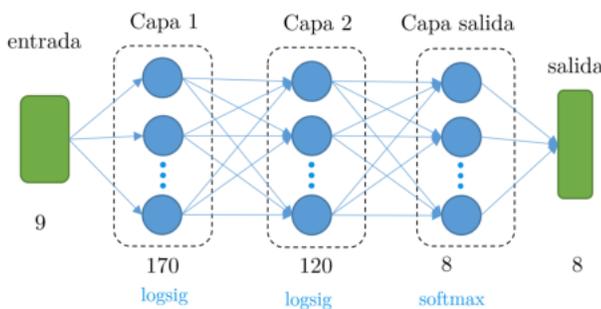


Figura 3. Estructura de la red neuronal con mejor desempeño

Para observar el desempeño de la RNA para clasificar correctamente las fallas, se presenta la matriz de confusión en la Figura 4. En la matriz de confusión, las filas son las clases reales (target class) y las columnas son las clases predichas por la RNA (output class); la diagonal principal contiene la suma de todas las predicciones correctas. Por lo que se observa, la clasificación en general es muy buena, pero existen errores persistentes de clasificación en la clase

1, dando falsos positivos, ya que detecta si hay falla pero no los asigna a la clase correcta.

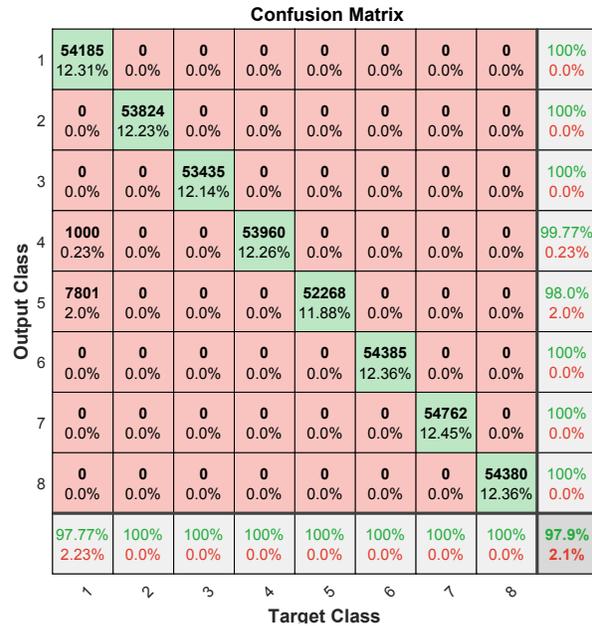


Figura 4. Matriz de confusión de la RNA propuesta

5. CONCLUSIONES

En este trabajo, se aplicó un enfoque de diagnóstico basado en datos utilizando ARR y un clasificador de RNA aplicado a un modelo de referencia de un aerogenerador. En la mayoría de los casos, el método fue capaz de clasificar diferentes escenarios de fallas, teniendo en cuenta el ruido de las mediciones del modelo de referencia. La calidad de los modelos utilizados para la detección de fallas es de importancia primordial para conocer el funcionamiento del aerogenerador, desde el punto de vista analítico, mediante las ecuaciones matemáticas que componen todo el sistema dinámico. Los subsistemas del aerogenerador están directamente relacionados y una falla puede verse reflejada en otro componente. Esto complica el aislamiento de las fallas cuando se presentan, además, existen factores externos al aerogenerador que complican el correcto diagnóstico de fallas; como la velocidad del viento. El análisis estructural mediante las ARR en conjunto con la clasificación de fallas por la RNA, nos da una perspectiva de solución al diagnóstico de fallas.

Para trabajos futuros, se pretende complementar el análisis de la dinámica del aerogenerador con datos obtenidos de manera experimental, para refinar el aprendizaje de los clasificadores ante incertidumbres perimétricas que limitan a los modelos teóricos. De manera que se pueda obtener un método híbrido de diagnóstico de fallas basado en modelos y datos reales.

REFERENCIAS

- Aguilar, C.Z., Gómez-Aguilar, J., Alvarado-Martínez, V., and Romero-Ugalde, H. (2020). Fractional order neural networks for system identification. *Chaos, Solitons & Fractals*, 130, 109444.
- Antoniadou, I., Dervilis, N., Papatheou, E., Maguire, A., and Worden, K. (2015). Aspects of structural health and condition monitoring of offshore wind turbines. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 373(2035), 20140075.
- Artigao, E., Martín-Martínez, S., Honrubia-Escribano, A., and Gómez-Lázaro, E. (2018). Wind turbine reliability: A comprehensive review towards effective condition monitoring development. *Applied energy*, 228, 1569–1583.
- Blesa, J., Puig, V., Romera, J., and Saludes, J. (2011). Fault diagnosis of wind turbines using a set-membership approach. In *Proceedings of IFAC world congress*, 8316–8321.
- Dey, S., Perez, H.E., and Moura, S.J. (2019). Robust fault detection of a class of uncertain linear parabolic pdes. *Automatica*, 107, 502–510.
- Habibi, H., Howard, I., and Simani, S. (2018). Reliability improvement of wind turbine power generation using model-based fault detection and fault tolerant control: A review. *Renewable energy*.
- Hameed, Z., Hong, Y., Cho, Y., Ahn, S., and Song, C. (2009). Condition monitoring and fault detection of wind turbines and related algorithms: A review. *Renewable and Sustainable energy reviews*, 13(1), 1–39.
- Hossain, M., Abu-Siada, A., and Muyeen, S. (2018). Methods for advanced wind turbine condition monitoring and early diagnosis: A literature review. *Energies*, 11(5), 1309.
- Leahy, K., Hu, R.L., Konstantakopoulos, I.C., Spanos, C.J., Agogino, A.M., and O’Sullivan, D.T. (2018). Diagnosing and predicting wind turbine faults from scada data using support vector machines. *International Journal of Prognostics and Health Management*, 9(1), 1–11.
- Lucas, F., Costa, P., Batalha, R., and Leite, D. (2018). High impedance fault detection in time-varying distributed generation systems using adaptive neural networks. In *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–8. IEEE.
- Mokhtari, A. and Belkheiri, M. (2018). Fault diagnosis of a wind turbine benchmark via statistical and support vector machine. In *International Journal of Engineering Research in Africa*, volume 37, 29–42. Trans Tech Publ.
- Odgaard, P.F., Stoustrup, J., and Kinnaert, M. (2013). Fault-tolerant control of wind turbines: A benchmark model. *IEEE Transactions on Control Systems Technology*, 21(4), 1168–1182.
- Puig, V., Quevedo, J., Escobet, T., Morcego, B., and Ocampo, C. (2010). Control tolerante a fallos (parte i): Fundamentos y diagnóstico de fallos. *Revista Iberoamericana de automática e informática industrial*, 1(1), 15–31.
- Quiñones-Grueiro, M., Prieto-Moreno, A., Verde, C., and Llanes-Santiago, O. (2019). Data-driven monitoring of multimode continuous processes: A review. *Chemometrics and Intelligent Laboratory Systems*.
- Rezamand, M., Kordestani, M., Carriveau, R., Ting, D.S., and Saif, M. (2019). A new hybrid fault detection method for wind turbine blades using recursive pca and wavelet-based pdf. *IEEE Sensors Journal*.
- Sanchez, H., Escobet, T., Puig, V., and Odgaard, P.F. (2015). Fault diagnosis of an advanced wind turbine benchmark using interval-based arrs and observers. *IEEE Transactions on Industrial Electronics*, 62(6), 3783–3793.
- Tornil-Sin, S., Ocampo-Martinez, C., Puig, V., and Escobet, T. (2013). Robust fault diagnosis of nonlinear systems using interval constraint satisfaction and analytical redundancy relations. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44(1), 18–29.
- Ugalde, H.M.R., Carmona, J.C., Reyes-Reyes, J., Alvarado, V.M., and Mantilla, J. (2015). Computational cost improvement of neural network models in black box nonlinear system identification. *Neurocomputing*, 166, 96–108.
- Villanueva, A. and Verde, C. (2018). Fault diagnosis for descriptor systems by equivalent transformations. *IFAC-PapersOnLine*, 51(24), 1239–1246.
- Wang, H., Lei, Z., Zhang, X., Zhou, B., and Peng, J. (2019). A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 198, 111799.
- Wang, Y., Ma, X., and Qian, P. (2016). Wind turbine fault detection and identification through pca-based optimal variable selection. *IEEE Transactions on Sustainable Energy*, 9(4), 1627–1635.
- Wang, Y., Ma, X., and Qian, P. (2018). Wind turbine fault detection and identification through pca-based optimal variable selection. *IEEE Transactions on Sustainable Energy*, 9(4), 1627–1635.
- Watson, S., Moro, A., Reis, V., Baniotopoulos, C., Barth, S., Bartoli, G., Bauer, F., Boelman, E., Bosse, D., Cherubini, A., et al. (2019). Future emerging technologies in the wind power sector: A european perspective. *Renewable and Sustainable Energy Reviews*, 113, 109270.
- Yang, H., Han, Q.L., Ge, X., Ding, L., Xu, Y., Jiang, B., and Zhou, D. (2019). Fault tolerant cooperative control of multi-agent systems: A survey of trends and methodologies. *IEEE Transactions on Industrial Informatics*.
- Yogitha, R. and Mathivanan, G. (2018). Performance analysis of transfer functions in an artificial neural network. In *2018 International Conference on Communication and Signal Processing (ICCSP)*, 0393–0397. IEEE.
- Yousefian, R. and Kamalasadani, S. (2017). A review of neural network based machine learning approaches for rotor angle stability control. *arXiv preprint arXiv:1701.01214*.