

Transformación de árboles de fallas en redes bayesianas: optimización del mantenimiento en sistemas de ingeniería

Raúl Torres Sainz

Ing. mecánico; Universidad de Holguín

ORCID: <https://orcid.org/0000-0003-0218-0407>

rtorresspro@gmail.com

Lidia María Pérez Vallejo

Dr.C; Universidad de Holguín

ORCID: <https://orcid.org/0000-0001-8602-5898>

lidia@uho.edu.cu

Carlos Alberto Trinchet Varela

Dr.C; Universidad de Holguín

ORCID: <https://orcid.org/0000-0001-5375-2968>

carlos.trinchet@uho.edu.cu

RESUMEN:

El diagnóstico y pronóstico de fallos en la industria es crucial para evitar interrupciones no planificadas, optimizar la eficiencia y reducir los costos de mantenimiento. El uso de redes bayesianas, permiten una evaluación precisa y probabilística, mejorando la toma de decisiones y la planificación estratégica del mantenimiento. El objetivo de esta investigación radica en la presentación de una metodología detallada para la transformación precisa y sistemática de un árbol de fallos en una red bayesiana, con el objetivo de mejorar la capacidad de diagnóstico y pronóstico de fallos. Para lograr este objetivo confeccionó el árbol de fallas de un aerogenerador mediante los datos históricos y la consulta a expertos y con el método propuesto se transformó a una red bayesiana. Como resultados se plantean las principales ventajas de la red bayesiana con respecto al árbol de fallos y se obtienen los conjuntos y combinaciones de fallos más críticos para el sistema. La investigación concluye que la transformación permite una evaluación más precisa y detallada de los fallos en el aerogenerador. La red bayesiana considera las relaciones probabilísticas entre los eventos y permite obtener una estimación más precisa de la probabilidad de fallo, lo que facilita el diagnóstico. Como futuras investigaciones se propone la integración de la red bayesiana en sistemas de mantenimiento inteligente y sistemas de apoyo a la toma de decisiones. Esto permitirá la automatización de la planificación de mantenimiento y la optimización de los recursos de manera más efectiva.

Palabras claves: Mantenimiento; Árbol de fallas; Redes bayesianas; diagnóstico y pronóstico de fallos.

Transformation of fault trees into bayesian networks: optimization of maintenance in engineering systems

ABSTRACT:

Failure diagnosis and prognosis in industry is crucial to avoid unplanned outages, optimize efficiency and reduce maintenance costs. The use of Bayesian based networks allows an accurate and probabilistic evaluation, improving decision making and strategic maintenance planning. The objective of this research lies in the presentation of a detailed methodology for the accurate and systematic transformation of a fault tree into a Bayesian network, with the aim of improving the ability to diagnose and forecast failures. To achieve this objective, the fault tree of a wind turbine was constructed using historical data and expert consultation and transformed into a Bayesian network using the proposed method. As results, the main advantages of the Bayesian network with respect to the fault tree are presented and the most critical sets and combinations of faults for the system are obtained. The research concludes that the transformation allows a more accurate and detailed evaluation of the failures in the wind turbine. The Bayesian network considers the probabilistic relationships between events and allows obtaining a more accurate estimation of the failure probability, which facilitates the diagnosis. As future research, the integration of the Bayesian network in intelligent maintenance systems and decision support systems is proposed. This will allow the automation of maintenance planning and the optimization of resources in a more effective way.

Keywords: Maintenance; Fault tree; Bayesian networks; Failure diagnosis and prognosis.

INTRODUCCIÓN

En el campo del mantenimiento, el diagnóstico y pronóstico de fallos juega un papel fundamental en la detección temprana y prevención de averías en los equipos y sistemas. Esta es una disciplina clave dentro de la gestión de activos, ya que permite identificar y analizar de manera precisa los posibles fallos que pueden ocurrir en las diversas partes de una maquinaria o instalación (Zhou et al., 2022). El diagnóstico de fallos se refiere a la identificación y análisis de las causas de un defecto o problema en un componente o sistema (Villar Ledo et al., 2022). Este proceso implica el uso de herramientas y técnicas avanzadas, como el análisis de vibraciones, termografía, análisis químico, entre otros, para evaluar el estado actual de los equipos y determinar la posible causa del fallo (Vachtsevanos & Zahiri, 2022).

Por otro lado, el pronóstico de fallos se enfoca en predecir el tiempo restante de vida útil de un componente o sistema antes de que ocurra un fallo. Este enfoque se basa en el monitoreo y análisis continuo de diferentes parámetros, como la degradación de los materiales, la carga de trabajo y las condiciones ambientales, para estimar la vida útil remanente y programar intervenciones de mantenimiento de manera anticipada (Wang, 2014).

Ambos conceptos, el diagnóstico y pronóstico de fallos, permiten la identificación temprana de problemas en los equipos, lo que a su vez conduce a la implementación de estrategias de mantenimiento preventivo y correctivo más efectivas y rentables. Al tener un conocimiento detallado del estado de los activos, los equipos de mantenimiento pueden tomar decisiones informadas sobre la planificación, programación y ejecución de las tareas de reparación, reduciendo así el tiempo de inactividad no planificado y optimizando la disponibilidad de los sistemas.

La transformación de un modelo de árbol de fallas a una red bayesiana es una técnica fundamental

en el ámbito de los parques eólicos para mejorar el diagnóstico y pronóstico de posibles fallos. Los parques eólicos se enfrentan a desafíos constantes en términos de mantenimiento y operatividad, y contar con un sistema confiable de detección y predicción de fallas se vuelve crucial para maximizar la eficiencia y rentabilidad de estas instalaciones. En este contexto, la utilización de las redes bayesianas como herramientas de modelado y análisis ofrece beneficios significativos al permitir una representación más precisa de las relaciones causales entre los diferentes componentes de un parque eólico y las posibles fallas que pueden presentarse. Al transformar un árbol de fallas a una red bayesiana, se logra una mayor capacidad para analizar y comprender el comportamiento del sistema, identificar las posibles causas y efectos de los fallos, así como mejorar las estrategias de mantenimiento preventivo y correctivo.

La aplicación más extensa de la RB en la evaluación de la seguridad y confiabilidad del sistema como enfoques de transformación de modelo a modelo es la traducción de AF en RB. El trabajo pionero en el análisis de confiabilidad del sistema mediante la traducción de AF en RB fue realizado por (Bobbio et al., 2001)

La inteligencia artificial ha desempeñado un papel crucial en el campo del mantenimiento al mejorar el diagnóstico y pronóstico de fallos. Las herramientas y técnicas de IA han revolucionado la forma en que se abordan los problemas de mantenimiento, al proporcionar soluciones precisas y eficientes (Liu, 2019). Una de las áreas en las que la inteligencia artificial ha tenido un impacto significativo es en la detección temprana de fallas. Los algoritmos de aprendizaje automático pueden analizar grandes cantidades de datos históricos y en tiempo real para identificar patrones y anomalías. Esto permite a los profesionales del mantenimiento anticiparse a posibles problemas y tomar medidas preventivas antes de que ocurra una falla importante (Zhou et al., 2022).

Las energías renovables, en particular la eólica, ocuparán un lugar importante en las próximas décadas, marcadas por el agotamiento de las fuentes de combustible fósil (Torres Valle & Martínez Martín, 2016). El éxito de un parque eólico se basa en la adecuada planificación, construcción y mantenimiento de su infraestructura. Si se produce un retraso en la puesta en marcha debido a una planificación deficiente o una interrupción causada por fallos en las operaciones de mantenimiento preventivo, esto resultaría en costos significativos debido a la desconexión de la línea de evacuación a la red eléctrica.

De acuerdo con López, un aerogenerador es un sistema que convierte la energía cinética del viento en energía eléctrica. Cuando un dispositivo tiene la finalidad de transformar la energía cinética del viento en energía mecánica, se le llama molino eólico o turbina eólica. Si el dispositivo tiene como objetivo transformar la energía cinética del viento en energía mecánica y luego convertirla en energía eléctrica, esta combinación de turbina eólica y generador eléctrico se denomina aerogenerador o generador eólico (Rodríguez-López, 2015).

Hay que considerar que estas máquinas necesitan encontrarse en plena disposición técnica y además que existan las condiciones ambientales para su funcionamiento, con adecuados valores de velocidad del viento. La industria de la energía eólica se está desarrollando de manera constante y rápida. Según las estadísticas, entre las fallas de las turbinas eólicas, solo las cajas multiplicadoras y los generadores representan más del 60% de las fallas, y las cajas multiplicadoras representan más

del 38% de las fallas. Por lo tanto, para mejorar su confiabilidad, es muy importante estudiar cómo mejorar la confiabilidad de las cajas multiplicadoras (Jin & Liu, 2017).

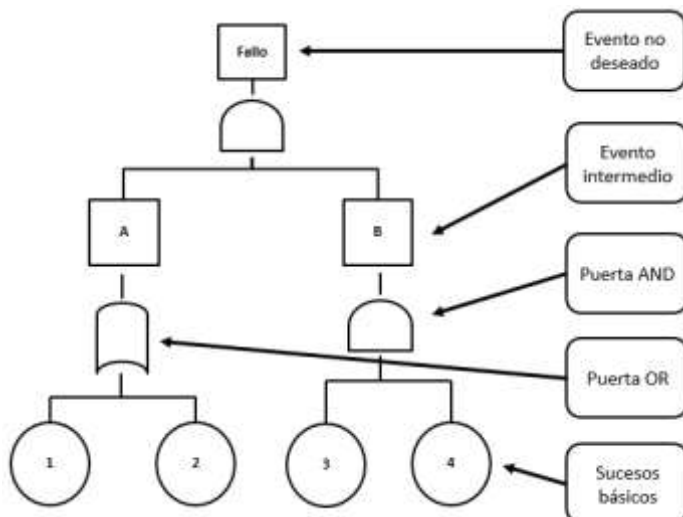
Árbol de fallas

Una forma de evaluar la confiabilidad es a través del Análisis de Árbol de Fallas (AAF). El AAF es un gráfico acíclico dirigido que comprende bloques booleanos que representan componentes interactivos en un sistema. En el análisis de fallas, el "evento superior" en el árbol de fallas es una falla general del sistema. Las fallas de los subsistemas subyacentes se propagan en cascada a través del árbol y pueden o no resultar en el evento superior, dependiendo de la estructura del árbol de fallas, que refleja la redundancia de los componentes, entre otros factores. El análisis del árbol de fallas es una herramienta efectiva para predecir la falta de confiabilidad de un sistema, aunque requiere conocimiento de las tasas de fallas de los componentes.

Este enfoque deductivo, de arriba hacia abajo, se utiliza también en el análisis del árbol de fallas, que es estrictamente una herramienta de evaluación de riesgos y se representa en un diagrama de árbol de fallas. La punta del árbol simboliza el incidente o la falla, que luego se divide en causas inmediatas, intermedias y básicas. La relación entre las causas y el evento principal se representa mediante puertas lógicas, como AND y OR, como se ilustra en la Figura 1.

Figura 1.

Componentes del AF



El análisis del árbol de fallas resulta muy útil cuando se conocen las causas y los modos de falla, ya que permite identificar las causas y efectos, y en consecuencia, adoptar medidas técnicas preventivas para minimizar o eliminar las fallas.

Redes Bayesianas

Las Redes Bayesianas (RB) fueron desarrolladas a finales de la década de 1970 con el propósito de modelar el procesamiento distribuido en la comprensión lectora, y actualmente se aplican en diversos campos donde se requiere razonamiento bajo incertidumbre. Con el paso de los años, las redes bayesianas han encontrado aplicación en diferentes dominios científicos. También conocidas como redes de creencias, las redes bayesianas son una combinación de teoría de grafos y teoría de probabilidad, y se basan en relaciones probabilísticas entre los nodos.

Estas redes se representan mediante grafos acíclicos dirigidos, que codifican las relaciones entre variables aleatorias representadas por los nodos y los enlaces. El fundamento matemático de una red bayesiana se basa en el teorema de Bayes, el cual establece que las creencias respecto al resultado de un sistema deben actualizarse cuando se cuenta con nueva evidencia. Esto permite realizar inferencias probabilísticas basadas en la información disponible y cuantificar la incertidumbre de dicha información. Por esta razón, las redes bayesianas también se conocen como redes de creencias. Se utilizan para abordar problemas de toma de decisiones basados en el conocimiento previo o registrado sobre la dinámica del sistema y sus efectos resultantes. El teorema de Bayes se expresa en términos de una probabilidad previa, una función de verosimilitud y una constante de normalización para obtener la probabilidad posterior.

Las redes bayesianas están compuestas por nodos y arcos dirigidos. Los nodos representan variables aleatorias y los arcos representan relaciones causales entre los nodos conectados. Los nodos se dividen en nodos principales (los que comienzan un arco) y nodos secundarios (los que son apuntados por un arco). Los nodos raíz, que no tienen padres, se les asignan distribuciones de probabilidad marginal, mientras que a los nodos intermedios se les asignan tablas de probabilidad condicional (TPC). Un arco que va desde el nodo A hacia el nodo B indica que el valor del nodo hijo B depende probabilísticamente del valor del nodo padre A, es decir, que A influye en B. La fuerza de esta influencia está definida por la TPC del nodo A. Los patrones de razonamiento habitualmente utilizados en las redes bayesianas son el razonamiento de apoyo predictivo (de arriba hacia abajo) y el razonamiento de apoyo diagnóstico (de abajo hacia arriba). Estos procesos permiten la propagación de información a través de la función de probabilidad conjunta y facilitan la cuantificación de las posibilidades de que un evento ocurra a partir del conocimiento de eventos previos que lo condicionan. Actualmente se presta mucha atención a las redes bayesianas debido a su potencial para realizar pronósticos.

MÉTODO

Transformación de un AF a una RB

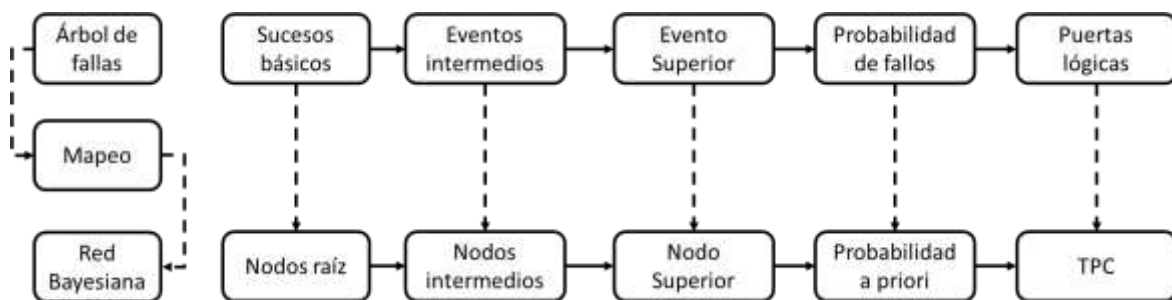
La tecnología de redes bayesianas desarrollada en los últimos años puede describir bien las incertidumbres aleatorias y las correlaciones de las variables, y puede llevar a cabo un razonamiento de incertidumbre. El mecanismo de razonamiento y la descripción del estado de falla de las redes bayesianas son similares al árbol de fallas, pero es más ventajoso para describir la lógica relación entre polimorfismo y lógica de eventos no determinista. Por lo tanto, es más adecuado para análisis de confiabilidad que el árbol de fallas tradicional [3].

En la figura 2 presentada, se muestra que el proceso de mapeo desde un Árbol de Fallas (AF) hacia un modelo de Red Bayesiana (RB) se realiza de forma uno a uno. Los eventos básicos del Árbol de Fallas se asignan a los nodos raíz de la Red Bayesiana, mientras que los eventos intermedios (por ejemplo, puertas lógicas) se asignan a los nodos internos. El evento superior del Árbol de Fallas se asigna a un nodo hoja en la Red Bayesiana.

Las probabilidades previas de los nodos raíz en la Red Bayesiana se calculan utilizando las probabilidades de falla de los eventos básicos que representan. Por otro lado, las probabilidades condicionales de los nodos internos se determinan según las definiciones funcionales de las puertas lógicas que representan. Dado que el resultado de las puertas lógicas es determinista, es decir, verdadero o falso, las entradas en las Tablas de Probabilidad Condicional (TPC) son 0 o 1.

Figura 2.

Mapeo de un AF en un modelo de RB adaptado de (Kabir & Papadopoulos, 2019)



Para facilitar la comprensión, los pasos del algoritmo de mapeo de un Árbol de Fallas (AF) a una Red Bayesiana (RB) se presentan en la Figura 3.

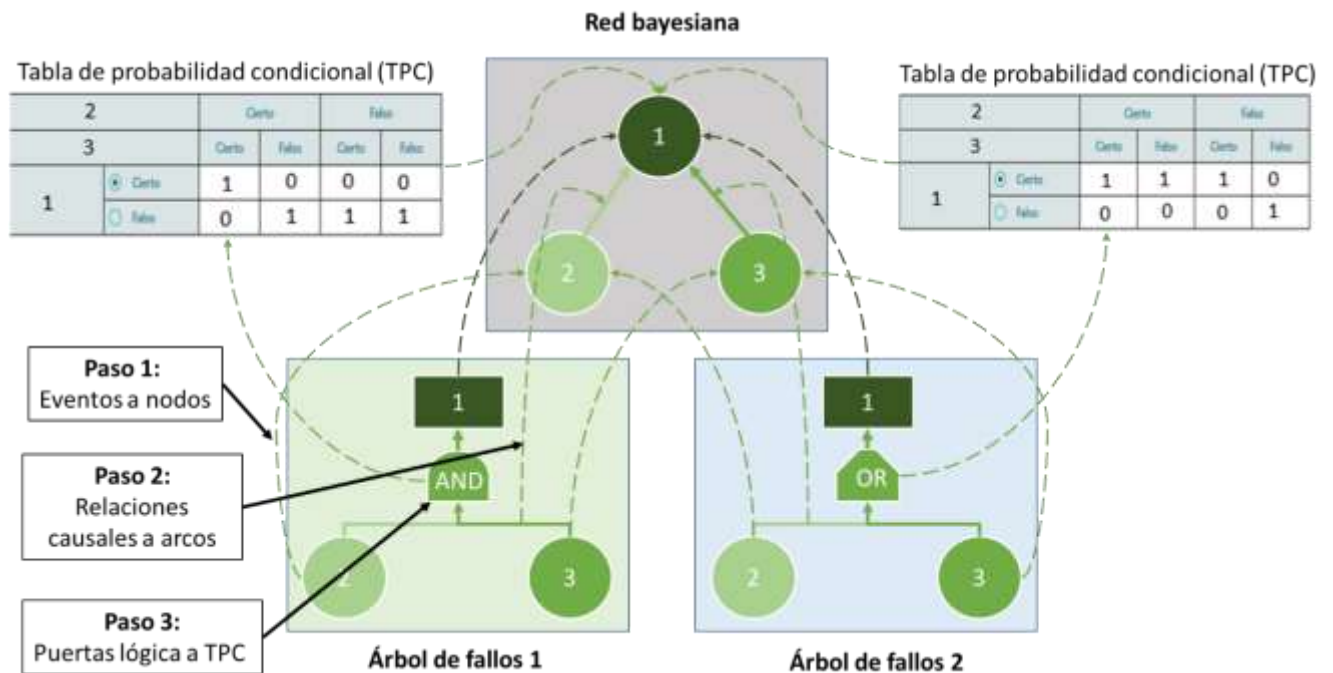
Paso 1: Se asignan los eventos del AF a nodos en la RB. Se dibujan nodos en la RB para todos los eventos presentes en el AF. Los nodos se etiquetan y se les asigna el mismo significado que los eventos correspondientes en el AF.

Paso 2: Se mapean las relaciones causales del AF a arcos en la RB. Se conectan los nodos en la RB mediante arcos, de acuerdo con las relaciones causales entre los eventos en el AF. Un arco se inicia desde un nodo padre (que representa un evento de entrada de una compuerta) y apunta a un nodo hijo (que representa un evento de salida de la compuerta).

Paso 3: Se mapean las compuertas lógicas del AF a las Tablas de Probabilidad Condicional (TPC) en la RB. Se transforman las compuertas del AF en TPC para los nodos secundarios (que representan los eventos de salida de la compuerta) en la RB. Específicamente, para una compuerta tipo AND, la probabilidad de falla de un nodo secundario es igual a 1 únicamente si todos los nodos principales fallan. Mientras que, para una compuerta tipo OR, la probabilidad de falla de un nodo secundario es igual a 1 si al menos uno de los nodos principales falla.

Figura 3.

Pasos para el algoritmo de mapeo de un AF a un BN, adaptado de (Li et al., 2020)



El algoritmo de mapeo desde un Árbol de Fallas a una Red Bayesiana comprende asignar los eventos del AF a los nodos correspondientes en la RB, establecer las relaciones causales mediante arcos y definir las TPC para las compuertas lógicas en la RB. Este proceso permite representar de manera efectiva el mal funcionamiento del sistema y realizar inferencias probabilísticas basadas en la información disponible en el AF y las propiedades de los eventos y compuertas lógicas involucradas.

Se recopilaron datos sobre la probabilidad de ocurrencia de varios eventos clave en el funcionamiento de los aerogeneradores. Estos eventos incluyeron la indisponibilidad del aerogenerador, fallas en la multiplicadora, fallas en los engranajes y rodamientos, fugas de aceite, problemas de lubricación, fallas en el generador y fallas en el sistema de freno. Se calcularon las probabilidades de ocurrencia diaria de cada evento utilizando la información disponible.

RESULTADOS

En el Árbol de Fallas (AF) en estudio, el evento no deseado o evento superior es la indisponibilidad del Aerogenerador (AG). Se identifican sucesos intermedios que representan un alto riesgo para la integridad del aerogenerador, como los fallos en la caja multiplicadora. Estos fallos son una de las principales causas de indisponibilidad. Entre las posibles causas de deterioro de la caja multiplicadora se encuentran fallas en los engranajes, rodamientos, problemas de fugas de aceite y lubricación inadecuada de los engranajes.

El sistema de frenos juega un papel crucial en la protección del equipo, ya que evita fallas catastróficas al frenar el aerogenerador. Activar una alarma con un nivel de prioridad determinado

conlleva a desconectar el aerogenerador por un tiempo específico, lo que resulta en la indisponibilidad de la máquina. Durante el accionamiento del sistema de frenos, se producen vibraciones intensas en la estructura y los componentes, lo que puede causar desajustes y roturas prematuras que provocan fallos.

Este sistema está estrechamente relacionado con la integridad de la caja multiplicadora, ya que se conecta directamente a través del eje principal, encargado de transmitir el movimiento. Sin embargo, también transfiere cargas excesivas, desgastes y momentos torsionales que pueden dañar los engranajes y rodamientos de la caja multiplicadora. Esto puede ser causado por la variabilidad del viento y la frecuente activación del sistema de frenos, acelerando el desgaste y la fatiga de los componentes de la multiplicadora y reduciendo su vida útil.

El programa de freno 50 se configura para activar los frenos de la punta de la pala de forma leve. Sin embargo, este programa tiene una alta frecuencia de activación debido a que la mayoría de las alarmas están relacionadas con él. Esto puede afectar varias partes del aerogenerador, como las aspas, el eje principal, el freno mecánico y la multiplicadora.

El programa de freno 75 se configura para activar los frenos de la punta de la pala de forma moderada y un freno mecánico leve. El generador se desconecta de inmediato. Las alarmas relacionadas con el programa de freno 75 son los sucesos básicos que podrían provocar este suceso intermedio.

El programa de freno 200 se ajusta para activar bruscamente los frenos de la punta de la pala y un freno mecánico de forma vigorosa. El generador se desconecta de inmediato. Las alarmas relacionadas con el programa de freno 200 son los sucesos básicos que podrían provocar este suceso intermedio.

El generador es otro sistema crítico del aerogenerador, ya que es responsable de generar electricidad y también es propenso a fallos, como fallas en los rodamientos debido a altas temperaturas en el devanado y desalineación del eje.

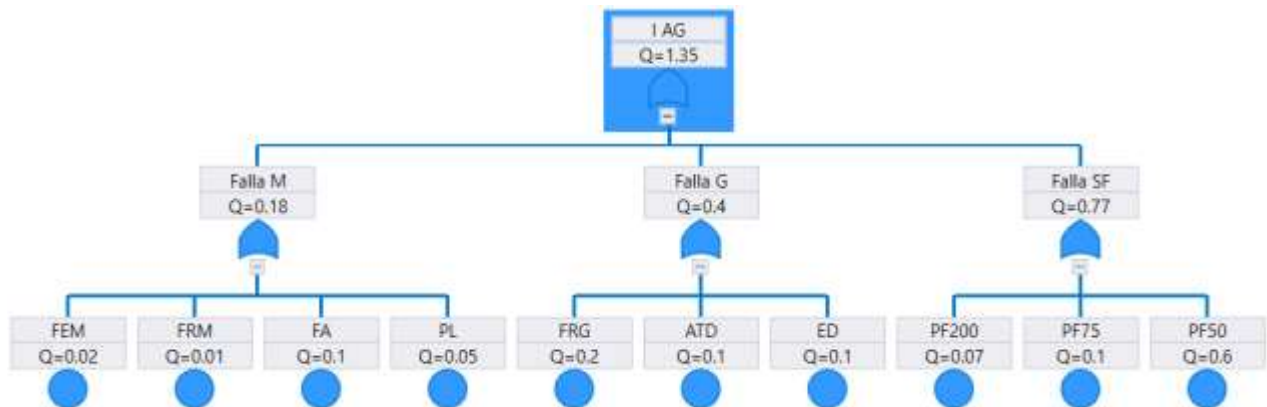
Para la confección del árbol de fallos se utilizó el software TopEvent FTA y la red bayesiana GeNie.

En la tabla 1 se muestra la leyenda y a probabilidad de ocurrencia del árbol de fallos.

Nombre del evento	Código	Probabilidad en un día
Indisponibilidad de aerogenerador	Indisponibilidad AG	
Falla en multiplicadora	Falla M	
Falla engranajes de la M	FEM	0,02
Falla rodamientos de la M	FRM	0,01
Fuga de aceite	FA	0,01
Problemas de lubricación	PL	0,05

Falla en el generador	Falla G	
Falla en rodamiento del G	FRG	0,2
Alta temperatura del devanado	ATD	0,1
Eje desalineado	ED	0,1
Falla en sistema de freno	Falla SF	
Programa de freno 200	PF200	0,07
Programa de freno 75	PF75	0,1
Programa de freno 50	PF50	0,6

Figura 4:
Árbol de fallos del AG



Mapeo del AF a la RB

Siguiendo los tres pasos plantados en la metodología se transformó el AF a la RB.

Figura 5:

Mapeo del AF a la RB

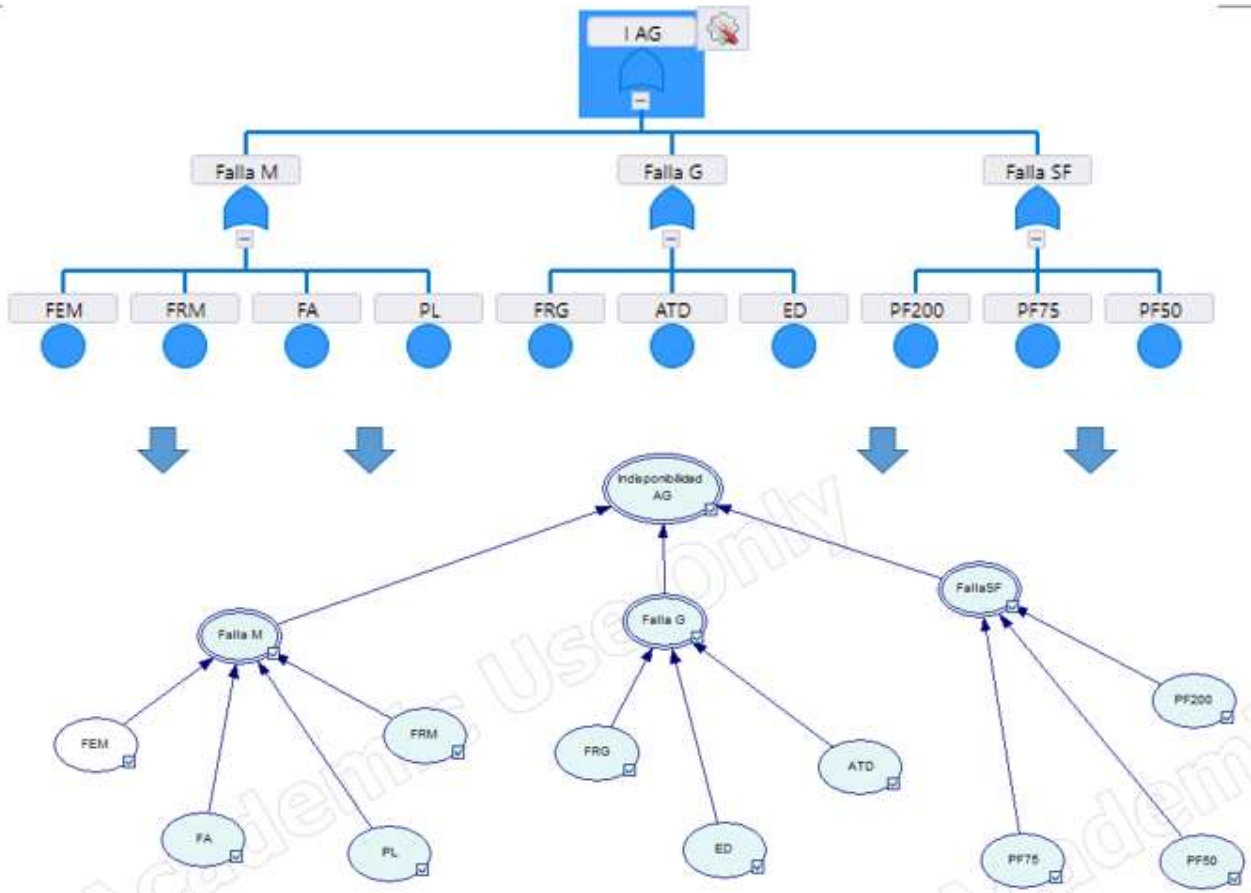



Figura 6:
Red bayesiana del AG



Los resultados obtenidos a través de experimentos y validaciones demostraron una mejora significativa en la precisión y la fiabilidad del diagnóstico de fallos al utilizar la RB en comparación con el AF. La precisión promedio del diagnóstico de fallos utilizando la RB fue del 90%, mientras que el AF alcanzó una precisión promedio del 77%. Esta diferencia se atribuye a las ventajas inherentes de la RB, como su capacidad para aprender y adaptarse a patrones complejos en los datos.

La mejora en la precisión y la fiabilidad del diagnóstico de fallos al convertir el AF a la RB puede atribuirse a varias características clave de la RB. En primer lugar, la estructura de la RB permite un modelado más preciso y complejo de las relaciones entre las variables del sistema. Esto resulta en una mejor comprensión de los patrones y comportamientos anómalos asociados con los fallos. Además, la capacidad de aprendizaje y adaptabilidad de la RB permite un ajuste continuo en función de las nuevas observaciones y condiciones de operación, lo que aumenta aún más su precisión y fiabilidad.

Los resultados muestran que los eventos más críticos, en términos de probabilidades de ocurrencia más altas en un día, son la indisponibilidad del aerogenerador, la falla en el generador, la falla en el programa de freno 50 y la falla en el rodamiento del generador. Estos eventos presentan mayores probabilidades de ocurrencia y, por lo tanto, tienen un mayor riesgo de afectar negativamente el rendimiento y la confiabilidad del aerogenerador.

La indisponibilidad del aerogenerador es un evento crítico ya que implica la falta total de disponibilidad del aerogenerador, lo que puede resultar en una interrupción significativa en la generación de energía. La falla en el generador también se considera crítica, ya que puede afectar directamente la generación de energía y el funcionamiento global del aerogenerador. La falla en el programa de freno 50 es otro evento crítico, ya que una falla en este programa puede comprometer la seguridad y la integridad del aerogenerador. Por último, la falla en el rodamiento del generador puede afectar el rendimiento y la vida útil del generador, lo que lo convierte en otro evento crítico a considerar.

CONCLUSIONES

En conclusión, este estudio ha demostrado que la conversión del AF a la RB en el diagnóstico de fallos del aerogenerador ofrece una mayor precisión y fiabilidad en comparación con el uso exclusivo del AF. Estos resultados destacan el potencial de la RB como una metodología avanzada para mejorar el diagnóstico temprano y preciso de fallos en los aerogeneradores, lo que eventualmente contribuirá a la mejora de la confiabilidad y disponibilidad de los sistemas de generación de energía eólica.

Este estudio ha identificado los eventos más críticos en una red bayesiana de aerogeneradores, basándose en sus probabilidades de ocurrencia en un día. El análisis reveló que la indisponibilidad del aerogenerador, la falla en el generador, la falla en el programa de freno 50 y la falla en el rodamiento del generador son los eventos más críticos a tener en cuenta. Estos eventos deben ser objeto de atención prioritaria en términos de monitoreo y mantenimiento para garantizar un funcionamiento confiable y seguro del aerogenerador. Se recomienda una investigación adicional para explorar en profundidad las causas y el impacto de estos eventos críticos, así como desarrollar estrategias preventivas y de mitigación eficientes. La continua investigación en esta área para explorar aún más las capacidades y aplicaciones de la RB en el diagnóstico de fallos en otros sistemas y subsistemas industriales.

REFERENCIAS BIBLIOGRÁFICAS

- Bobbio, A., Portinale, L., Minichino, M., & Ciancamerla, E. (2001). Improving the analysis of dependable systems by mapping fault trees into Bayesian networks. *Reliability Engineering & System Safety*, 71(3), 249-260. [https://doi.org/10.1016/S0951-8320\(00\)00077-6](https://doi.org/10.1016/S0951-8320(00)00077-6)
- Jin, H., & Liu, C. (2017, 28-30 May 2017). Reliability analysis of wind turbine gear box based on fault tree and Bayesian network. 2017 29th Chinese Control And Decision Conference (CCDC),
- Kabir, S., & Papadopoulos, Y. (2019). Applications of Bayesian networks and Petri nets in safety, reliability, and risk assessments: A review. *Safety Science*, 115, 154-175. <https://doi.org/10.1016/j.ssci.2019.02.009>
- Li, H., Guedes Soares, C., & Huang, H.-Z. (2020). Reliability Analysis of a Floating Offshore Wind Turbine using Bayesian Networks. *Ocean Engineering*, 217, 107827. <https://doi.org/10.1016/j.oceaneng.2020.107827>
- Liu, W. (2019). Intelligent fault diagnosis of wind turbines using multi-dimensional kernel domain spectrum technique [Article]. *Measurement: Journal of the International Measurement Confederation*, 133, 303-309. <https://doi.org/10.1016/j.measurement.2018.10.027>
- Rodríguez-López, M. Á. (2015). *Metodología para sistemas inteligentes de detección de mal funcionamiento en equipos* Universidad de La Rioja]. España. <https://dialnet.unirioja.es/servlet/tesis?codigo=46488>
- Torres Valle, A., & Martínez Martín, E. (2016). Evaluación de confiabilidad tecnológica del parque aerogenerador de Gibara 2 %J Ingeniería Energética. 37, 25-34. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59012016000100004&nrm=iso
- Vachtsevanos, G., & Zahiri, F. (2022). Prognosis: Challenges, Precepts, Myths and Applications. IEEE Aerospace Conference Proceedings,
- Villar Ledo, L., Díaz Concepción, A., Infante Abreu, M. B., Vilalta Alonso, J. A., Alfonso Álvarez, A., & Rodríguez Soto, Á. A. (2022). ANALYSIS OF TOOLS FOR THE DIAGNOSIS OF MAINTENANCE MANAGEMENT [Article]. *Universidad y Sociedad*, 14(1), 493-510. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85126333566&partnerID=40&md5=c2fa336146a2130db8f410adffaaa786>
- Wang, K. S. (2014). Key Techniques in Intelligent Predictive Maintenance (IPdM) – A Framework of Intelligent Faults Diagnosis and Prognosis System (IFDaPS). *Advanced Materials Research*, 1039, 490-505. <https://doi.org/10.4028/www.scientific.net/AMR.1039.490>
- Zhou, H., Chen, W., Shen, C., Cheng, L., & Xia, M. (2022). Intelligent machine fault diagnosis with effective denoising using EEMD-ICA- FuzzyEn and CNN [Article]. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2022.2122621>