

Modelo de comportamiento de una turbina eólica

Uriel A. García, Pablo H. Ibargüengoytia, Alberto Reyes, Mónica Borunda

Instituto de Investigaciones Eléctricas,
Cuernavaca, Morelos, México

{uriel.garcia,pibar,areyes,monica.borunda}@iie.org.mx

Resumen. El comportamiento de un equipo puede verse como las variaciones en algunos de sus parámetros cuando existen cambios en el ambiente del equipo. El presente artículo muestra cómo el mecanismo de las redes Bayesianas pueden ser usadas para aprender un modelo probabilista del comportamiento. Con ese modelo, es posible la identificación de desviaciones al comportamiento normal. Es decir, realizar un diagnóstico en línea del equipo. Este artículo describe el modelo de comportamiento de una turbina eólica y los experimentos preliminares para identificar desviaciones al comportamiento normal. Se presentan experimentos para el aprendizaje del modelo usando datos históricos y experimentos de validación del modelo usando casos de estudio en que se presentó una falla en la turbina.

Palabras clave: Turbinas eólicas, comportamiento, diagnóstico, redes Bayesianas, SCADA.

Model of the Behaviour of Wind Turbine

Abstract. The behavior of an equipment can be seen as the variations of some parameters when changes in the environment are experienced. This paper describes how Bayesian networks can be used to learn a probabilistic model of the equipment's behavior. Using this model, it is possible to identify deviations to the normal behavior. This means that on-line diagnosis can be executed. This paper describes the behaviour model of a wind turbine and the preliminary experiments to identify deviations. The experiments to learn the model based on historical data are presented and the experiments to validate the model using a turbine failure data.

Keywords: Wind turbines, behavior, diagnosis, Bayesian networks, SCADA.

1. Introducción

El diccionario de la Real Academia Española define al comportamiento como sigue:

Comportamiento o conducta es la manera de proceder que tienen las personas u organismos, en relación con su entorno o mundo de estímulos.

El comportamiento puede ser consciente o inconsciente, voluntario o involuntario, público o privado, según las circunstancias que lo afecten.

En el caso de procesos o sistemas industriales, la definición incluiría la manera de proceder del sistema de acuerdo a su entorno y a los estímulos que reciba. Entonces, se puede describir el comportamiento de un proceso industrial como las variaciones que tienen sus variables principales dadas las variables de entrada al proceso y el entorno.

El trabajo de investigación reportado en este artículo pretende la modelación del comportamiento de una turbina eólica. Se requiere entonces modelar el proceder adecuado de la turbina de acuerdo al entorno suyo y a los estímulos que puede recibir. Entonces, el modelo deberá indicar los cambios que se registran en las partes de la turbina cuando se resienten cambios en el entorno. En otras palabras, algunas variables tendrán valores diferentes cuando otras variables cambien de valor.

Para el caso de la turbina eólica se decidió tomar a las variables que se registran en el sistema de control supervisorio y de adquisición de datos (SCADA por sus siglas en inglés) como las variables que caracterizarán el comportamiento de la turbina. Se propone el uso de redes Bayesianas (RB) para la generación de modelos de comportamiento de equipo industrial. Las RB codifican las relaciones probabilistas entre las variables del equipo. Se puede identificar las variables dependientes entre ellas, las variables independientes y las relaciones condicionales entre varias variables. Formalmente, las RB son grafos acíclicos dirigidos que codifican relaciones probabilistas entre variables. Los nodos de una RB representan a las variables mientras que los arcos dirigidos representan relaciones probabilistas. El nodo destino de un arco (el hijo) es dependiente del origen del arco (el padre).

La RB aprendida se considera exclusivamente como un modelo que codifica el comportamiento de la turbina. Dados los valores de unas variables, podremos calcular las probabilidades del valor de otras variables. Entonces, comparando los valores estimados con los valores reales observados en el SCADA, podremos identificar desviaciones a ese comportamiento. Esta idea sigue la teoría de la validación de sensores desarrollada anteriormente [3]. Aunque en aquel trabajo se buscó identificar cuando un sensor mandaba información incorrecta, se desarrolla en este proyecto la idea que, al detectar información inesperada, el sensor esté funcionando correctamente pero el equipo no está comportándose correctamente.

Este artículo se organiza como sigue. La siguiente sección introduce brevemente el formalismo de las redes Bayesianas. La sección 3 explica las principales características de una turbina eólica. Sus partes que la componen y algunas de las variables que se manejan en el sistema SCADA. En seguida, la sección 4

expone la construcción del modelo del comportamiento de la turbina y muestra la red Bayesiana resultante. En seguida, se explica la forma de identificar la desviación al comportamiento normal representado por el modelo Bayesiano en sección 5. La sección 6 describe los experimentos que se han realizado para la validación del modelo de comportamiento de la turbina, así como su capacidad para identificar fallas o desviaciones al comportamiento normal. Finalmente, la sección 7 concluye el artículo, discute los resultados y muestra la dirección que este trabajo de investigación llevará en el futuro.

2. Introducción a las redes Bayesianas

Las redes Bayesianas (RB) [5] fueron creadas para representar incertidumbre en sistemas inteligentes. Fueron desarrolladas con la conjunción de teoría de probabilidad con la teoría de grafos. Por definición, las RB son grafos acíclicos dirigidos que representan las relaciones probabilistas entre las variables del proceso. Los nodos representan las variables u objetos del dominio de aplicación, mientras que los arcos representan las relaciones probabilistas entre los nodos enlazados. El conocimiento es representado en RB de dos formas:

Cualitativamente con la estructura de la red. Se muestra cuáles nodos son dependientes y cuáles son independientes.

Cuantitativamente con los parámetros que forman las probabilidades a-priori de los nodos raíz y las matrices de probabilidad condicional de los nodos hijos dados los valores de los nodos padres.

La estructura se adquiere utilizando conocimiento de expertos que puedan indicar las relaciones probabilistas entre variables. Sin embargo es difícil tener ese conocimiento en aplicaciones reales. Para esto, existen una buena variedad de algoritmos de aprendizaje automático que proporcionan la estructura de RB en base a datos históricos del proceso [4].

Los parámetros también pueden ser proporcionados por expertos en el tema o aprendidos automáticamente con los algoritmos apropiados. Juntando las características del problema de la representación del conocimiento con las características de las RB, éstas resultan un magnífico enfoque para modelar ese conocimiento. La Fig. 2 muestra un ejemplo de modelo para la representación del comportamiento de una turbina eólica.

3. Turbinas eólicas

Las turbinas eólicas se nombran en base a la orientación del eje de pala de rotor en horizontales o verticales. El viento se aprovecha y se convierte en electricidad mediante las turbinas eólicas, la cantidad de electricidad que produce una turbina depende de su tamaño y la velocidad del viento. Las turbinas de eje horizontal se caracterizan por compartir diseño y partes básicas: palas, rotor, eje central, multiplicadora, generador, torre, góndola, freno. Estas partes trabajan

en conjunto para convertir la energía cinética del viento en energía mecánica que genera electricidad. La Fig. 1 muestra un diagrama de partes de la turbina marca Komai.

Las secciones de una turbina se describen a continuación:

Rotor: Se encuentra conectada al eje principal, elemento rotatorio para recibir la energía a partir del viento mediante sus tres palas conectadas al buje del rotor.

Soportes o rodamientos: Se cuenta con soportes para el sistema yaw, pitch, eje principal del rotor y el rotor que son monitoreados conforme a su temperatura.

Sistema de orientación: Los aerogeneradores cuentan con dos sistemas de orientación en relación a la dirección del viento. El primer sistema se refiere a la posición de la góndola (yaw) y el segundo sistema es la posición adecuada de las paletas (pitch) con la cual se controla la velocidad del rotor.

Sistema de enfriamiento: Elemento indispensable para evitar las altas temperaturas en el interior de la góndola y disminuir las condiciones extremas de sus componentes.

Sistema de frenado: Dispositivo de bloqueo que frena la rotación del rotor poniéndolo en un punto muerto. El evento se genera de manera manual o automático por ejemplo en caso de mantenimiento o exceso de viento.

Mástil meteorológico: Está equipada para medir velocidad y dirección del viento con un alto grado de precisión y transmite la información al controlador. Cuenta con anemómetros y veletas rodeado de tubos de metal que funcionan como pararrayos.

Generador: Se encuentra conectada a la caja multiplicadora la cual convierte la energía mecánica en energía eléctrica produciendo electricidad.

Multiplicadora de velocidad: Conecta el eje de baja velocidad al eje de alta velocidad e incrementa la velocidad rotacional del generador requerida para producir electricidad. Por ejemplo en la turbina Komai, la relación de transmisión es de un aumento rotacional nominal del rotor de 40.5 rpm a 1795 rpm de la rotación del generador.

Góndola: Se encuentra sobre la torre y contiene la caja multiplicadora, eje de baja y alta velocidad, generador, controlador, sistema de frenado etc. Es monitoreado por vibración y temperatura.

SCADA es una aplicación de software para el control y monitoreo con los datos medidos por PLC, el cual se encarga de la comunicación con los dispositivos instalados en el aerogenerador para la adquisición de datos. El software se encarga de almacenar, procesar, supervisar y controlar la información recibida a través de su IHM (interfaz hombre maquina) el cual permite modificar parámetros de funcionamiento de la turbina eólica. LA IHM del SCADA permite visualizar y adquirir una serie de variables que describen el comportamiento de los sensores instalados en la turbina apreciando el nombre de la variable, valores medidos en promedios de 5 minutos, desviaciones estándar, valores mínimos y máximos.

La Tabla 1 muestra un ejemplo de variables correspondientes a los diferentes equipos que forman la turbina. Se muestran tres variables de tres equipos.

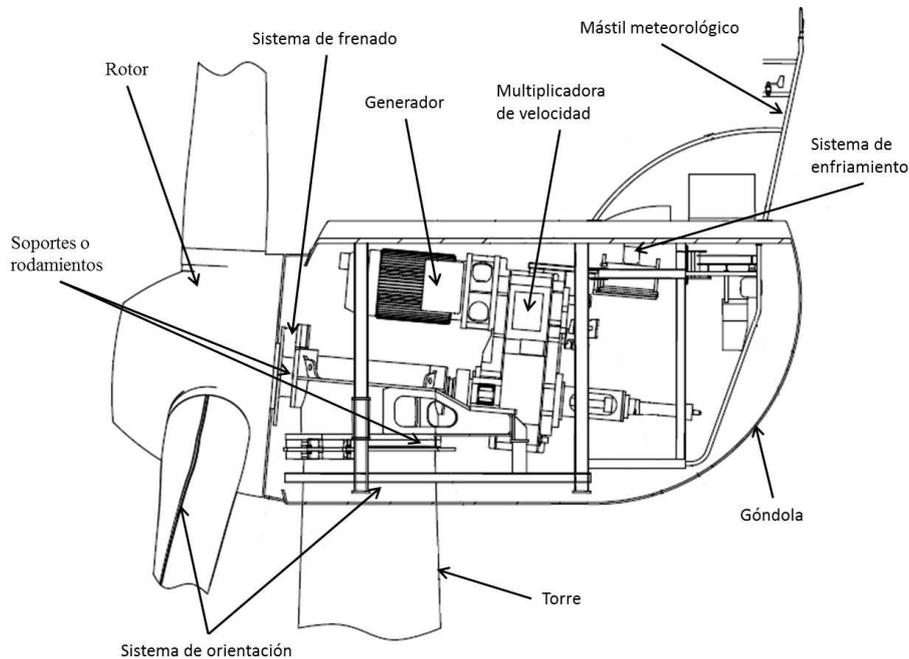


Fig. 1. Modelo de la turbina marca Komai.

4. Representación del comportamiento de turbinas eólicas

Para el aprendizaje del modelo probabilista del comportamiento de la turbina eólica, se utilizó uno de los algoritmos de aprendizaje de redes Bayesianas incluidas en el paquete *Hugin* [1]. Específicamente, utilizamos el algoritmo *Gready and search* [2]. Para ese aprendizaje, se siguió el procedimiento a continuación:

1. Identifica un conjunto de datos históricos en que un experto pueda sugerir comportamiento normal de la turbina. Utiliza el formato de datos separados por coma (csv). Mientras más grande este conjunto de datos mejor, ya que se presentarán diferentes condiciones de operación de la turbina.
2. Detecta los datos inconsistentes (*outliers*) y elimínalos del archivo de datos.
3. Discretiza el conjunto de datos utilizando partición uniforme. El número de intervalos depende del poder de cómputo disponible. A más intervalos, se aprenden modelos más caros computacionalmente.
4. Corre el algoritmo de aprendizaje de redes Bayesianas usando el paquete *Hugin*. Depura el modelo. Esto es, si al generar la red Bayesiana resulta en nodos aislados de la red, elimínalos del conjunto de datos y repite los pasos anteriores.

Fig. 2 muestra el modelo aprendido. Nótese por ejemplo algunas relaciones que se perciben lógicas cómo las relaciones entre los nodos *WindSpeed* y

Tabla 1. Ejemplo de diferentes equipos que forman la turbina y sus variables

Sistema de orientación			Generador			Rotor		
Variable	Un.	Descripción	Variable	Un.	Descripción	Variable	Un.	Descripción
Pitch Angle	o	Regula el ángulo de paso de las aspas del rotor	Bearing temp DE	o	Temperatura interior de chumacera	Bearing Temp A DriveEnd	o	Temperatura de chumacera en posición A
Pitch Pressure	bar	Control de presión del ángulo de paso de las aspas	Bearing temp NDE	o	Temperatura exterior de chumacera	Bearing Temp B NoDriveEnd	o	Temperatura de chumacera en posición B
Brake Pressure	bar	Presión de frenado	Generator Speed	rpm	Velocidad del generador	Rotor Speed	rpm	Velocidad del rotor

InverterMotorCurrent, *GeneratorSpeed* y *Vibration*. Es decir, si existe una velocidad de viento alta, se espera que la velocidad del generador esté alta, que las vibraciones aumenten así como la corriente en el inversor. De igual manera, si hay poco viento, las demás variables se comportarán con valores bajos. La intensidad de estas relaciones está dada por las tablas de probabilidad condicional que conforman el modelo completo. Con este modelo, se puede hacer una estimación probabilista y comprobar si ambas cantidades están de acuerdo. En caso contrario, se detecta una desviación al comportamiento normal que habrá que profundizar. La siguiente sección describe ese proceso.

5. Detección de desviaciones al comportamiento normal

Las RB representan un enfoque apropiado para el modelado del comportamiento de las turbinas eólicas. Sin embargo, lo importante será la detección de desviaciones del comportamiento normal. Esto se realiza utilizando la teoría de validación de sensores desarrollada anteriormente [3]. En objetivo de esa teoría es la identificación de fallas en sensores en un proceso industrial. La idea es la identificación de valores atípicos de una variable de acuerdo a los valores de las variables más relacionadas. Sin embargo, en este artículo desarrollamos la idea de que un sensor puede marcar como erróneo pero no por falla del sensor sino por desviación del comportamiento del proceso.

Esta teoría se desarrolla en dos fases:

1. detección de una desviación al comportamiento normal y
2. aislamiento o identificación de la variable con falla.

La fase de detección se realiza en un ciclo donde cada variable es estimada en la RB y comparada con su valor real. Para esto, se asigna valores a

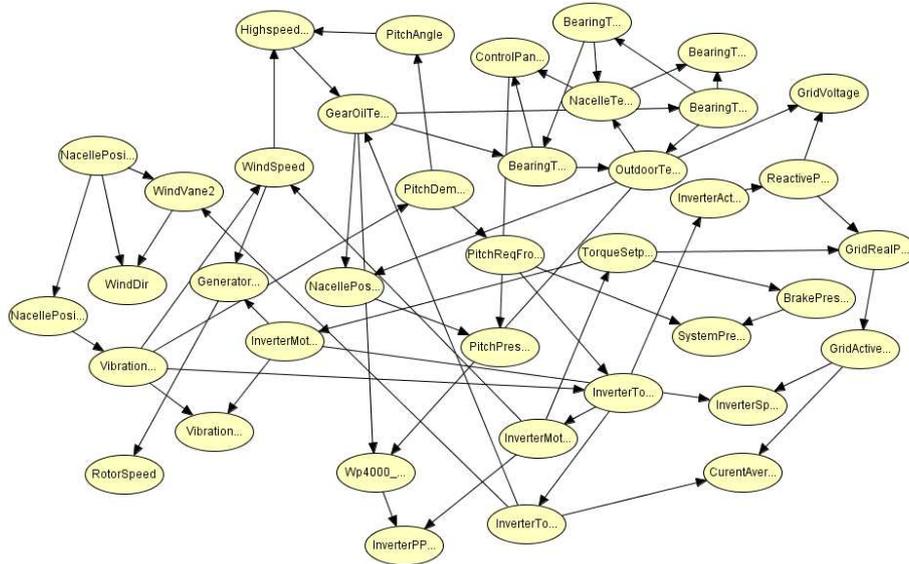


Fig. 2. Modelo de comportamiento aprendido.

las variables relacionadas a la variable en observación y se propaga las probabilidades del nodo. En caso de existir una diferencia importante, se declara una falla aparente o potencial. La fase de aislamiento recibe el conjunto de nodos con fallas aparentes generada en la fase de detección e identifica cuál es la falla real. Esta identificación se realiza utilizando la propiedad de la cobija de Markov de una RB [5]. La cobija de Markov de un nodo en una red Bayesiana está formada por el conjunto de los nodos padres, más los nodos hijos más los nodos esposos, es decir, los otros padres de los hijos. Por ejemplo, en la Fig.2, la cobija de Markov del nodo *WindSpeed* son los nodos $\{Vibration, InverterMV, Generator, Highspeed, PitchAngle, InverterMC\}$. En suma, después del ciclo de detección, el nodo cuya cobija de Markov coincida con el conjunto de fallas aparentes, entonces esa variable es la que provocó la falla real. Sin embargo, en este proyecto de investigación se pretende identificar no solo las fallas de sensores individuales sino además, desviaciones del comportamiento normal de la turbina. La siguiente sección describe los primeros experimentos en esa detección de desviación del comportamiento.

6. Experimentos de validación

Se utilizaron 39 variables de la base de datos del sistema SCADA para la construcción del modelo de comportamiento de una turbina eólica incluyendo mediciones de temperatura, presión, vibración, posición, velocidades, potencia, corriente entre otras involucradas en los diferentes equipos de una turbina.

La Tabla 2 muestra las 39 variables utilizadas con sus nombres como vienen en el SCADA. Se menciona las unidades de las variables.

Tabla 2. Lista de variables usadas en el modelo de comportamiento

Nombre de variable	Unidad	Nombre de variable	Unidad
GridRealPower100ms	kW	NacellePosition	o
GridActivePower	kW	PitchReqFromPitchControleller	o
TorqueSetpoint	Nm	PitchAngle	o
CurentAverage3phase_32bit	A	PitchDemand	o
ReactivePower1	kVar	NacellePositionRelativeToWindDirection	o
WindSpeed	m/s	NacellePositionRelativeToWindDirection30s	o
Vibration1WP4084_1	G	WindDir	o
Vibration2WP4084_1	G	WindVane1	o
PitchPressure	bar	Wp4000_Temp	o C
SystemPressure	bar	BearingTemp_A	o C
BrakePressure	bar	BearingTemp_B	o C
RotorSpeed	rpm	GearOilTemperature	o C
GeneratorSpeed	rpm	HighspeedBearingTemp	o C
InverterMotorVoltage	rpm	Bearing temp DE	o C
InverterTorqueReference	%	BearingTempNDE	o C
InverterTorque	%	InverterPP1Temperature	o C
InverterActivePower	%	OutdoorTemperatureLog	o C
InverterMotorVoltage	V	ControlPanelTemperature	o C
InverterMotorCurrent	V	NacelleTemperature	o C
GridVoltage	V		

Para la generación del modelo de comportamiento se utilizó un conjunto de datos limpios, el modelo se construyó con un año de información adquirida a cada 5 minutos en condiciones normales de operación de la turbina eólica. Se consideró para el conjunto de prueba datos con condiciones de operación irregulares.

Usando las 39 variables y la información histórica de un año, se construyó el modelo de comportamiento mostrado en la Fig.2. Con esa red Bayesiana, se realizaron los siguientes experimentos:

Para el obtener los resultados presentados en la Fig. 3. Se siguió el procedimiento a continuación:

1. Identificar el conjunto de variables en la base de datos del SCADA. El conjunto de datos de pruebas utiliza el formato de datos separados por coma (csv).
2. Seleccionar datos con comportamiento inconsistente en la generación de potencia.
3. Correr el modelo de comportamiento con el conjunto de datos de prueba.
4. Visualizar resultados de fallas reales.

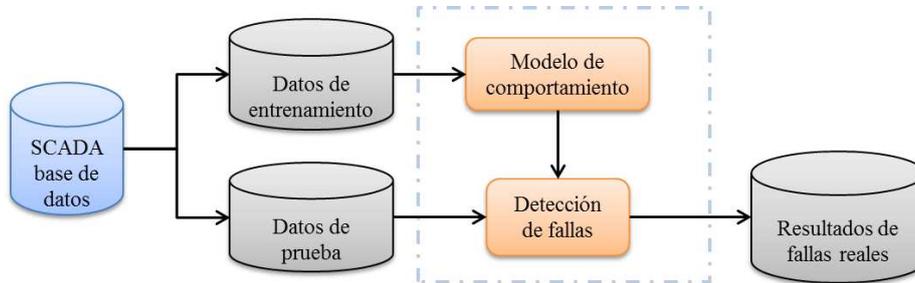


Fig. 3. Diagrama a bloques del procedimiento de validación.

La Fig. 4 muestra una sección de los datos seleccionados para la validación del modelo. Se muestran únicamente las variables de velocidad del viento (WindSpeed) y de la potencia generada (GridActivePower). Se puede apreciar un momento en que la potencia generada tuvo una leve caída y más adelante, se puede apreciar una caída total de la generación. Se puede suponer que en estos momentos sucedió algún evento que forzó al cambio de comportamiento de la turbina. La Fig. 5 muestra la detección de comportamiento anormal de algunas variables. En el eje vertical se puede apreciar la probabilidad de falla detectada en esas variables.

Se observa en los resultados las fallas evidentes de las siguientes variables: Bearing temp DE (temperatura interior de soportes del generador), Bearing-Temp_A (temperatura de soportes del eje principal), GridVoltage (Voltaje en la Red), NacellePosition (Posición de la góndola), ControlPanelTemperature (Temperatura de panel de control de la turbina eólica).

Sobreponiendo las dos figuras, se hace contraste a la generación de potencia de la turbina eólica donde se aprecian caídas de potencia e instancias de inestabilidad en la generación. Esto valida la capacidad del modelo para la detección de comportamiento anormal. Cuando se presenta algún evento inesperado, que puede ser falla en algún componente de la turbina, se genera un patrón de fallas en algunas variables del modelo. Ese patrón de variables en falla se clasificará para poder hacer un diagnóstico completo y en línea de la turbina eólica.

7. Conclusiones y trabajo futuro

Se muestra en este artículo los avances del proyecto que persigue el diagnóstico inteligente de turbinas eólicas. El enfoque que se utiliza es el de modelado del comportamiento de la turbina para poder identificar desviaciones a éste. Se describe en el artículo el enfoque para crear el modelo de comportamiento usando redes Bayesianas y se describen los experimentos iniciales que muestran que es posible la detección de comportamiento anormal. Se utilizó un conjunto de datos para la prueba donde se puede apreciar dos comportamientos sospechosos y cómo se muestran en el sistema. Sin embargo, el trabajo seguirá atendiendo las siguientes preguntas abiertas:

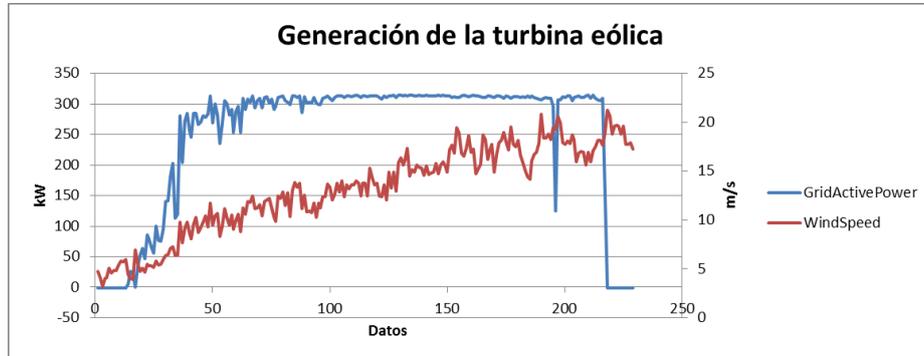


Fig. 4. Gráfica que muestra el comportamiento de la velocidad del viento y la generación de potencia.

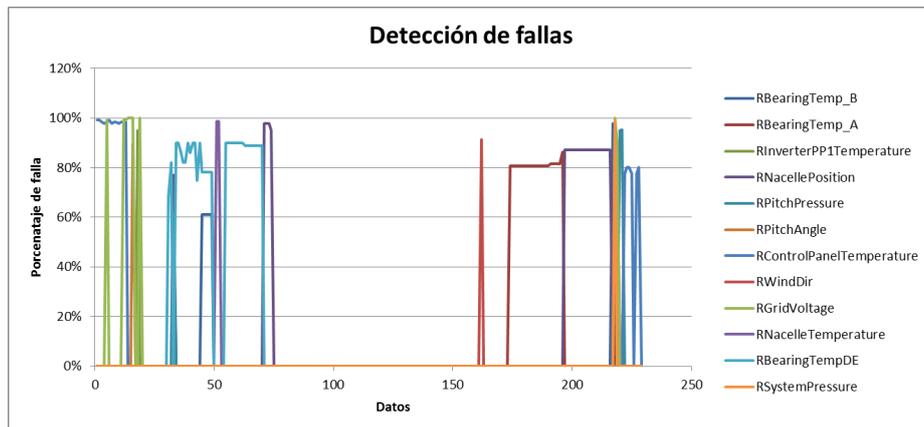


Fig. 5. Gráfica que muestra la identificación de patrones de falla de algunas variables.

- se podrá identificar modelos de comportamiento más compactos según las diferentes partes de la turbina? Esto generaría un conjunto de modelos que podrán estar interconectados formando redes Bayesianas multi-seccionadas [6].
- según la definición de comportamiento, se podrá identificar diferentes contextos del ambiente para analizar el comportamiento apropiadamente en cada contexto? No es lo mismo el comportamiento de la turbina con bajos vientos que con los vientos de mayor velocidad como los de la región de Oaxaca.
- se requerirá de la identificación de patrones de desviaciones detectadas para caracterizar fallas específicas de la turbina?
- será posible detectar esas fallas de manera insipiente?

El proyecto seguirá avanzando para responder las preguntas planteadas.

Agradecimientos. El trabajo reportado en este artículo es financiado por la Secretaría de Energía y el CEMIE-Eólico del Fondo Sectorial de Sustentabilidad del Conacyt en México. Se agradece la información proporcionada por el CERTE del IIE.

Referencias

1. Andersen, S.K., Olesen, K.G., Jensen, F.V., Jensen, F.: Hugin: a shell for building bayesian belief universes for expert systems. In: Proc. Eleventh Joint Conference on Artificial Intelligence, IJCAI. pp. 1080–1085. Detroit, Michigan, U.S.A. (20-25 August 1989)
2. Chickering, D.: Optimal structure identification with greedy search. *Journal of Machine Learning Research* 3, 507–554 (2002)
3. Ibarzüengoytia, P.H., Vadera, S., Sucar, L.: A probabilistic model for information and sensor validation. *The Computer Journal* 49(1), 113–126 (January 2006)
4. Neapolitan, R.: *Learning Bayesian Networks*. Prentice Hall, New Jersey (2004)
5. Pearl, J.: *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann, San Francisco, CA. (1988)
6. Xiang, Y.: A probabilistic framework for cooperative multi-agent distributed interpretation and optimization of communication. *Artificial Intelligence* 87, 295–342 (1996)