INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY

CAMPUS MONTERREY

PROGRAMA DE GRADUADOS EN MECATRÓNICA Y TECNOLOGÍAS DE LA INFORMACIÓN

TESIS

DIAGNÓSTICO DE FALLAS EN REDES ELÉCTRICAS INDUSTRIALES MEDIANTE REDES BAYESIANAS HÍBRIDAS

PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL GRADO ACADÉMICO DE LA MAESTRÍA EN CIENCIAS CON ESPECIALIDAD EN AUTOMATIZACIÓN

POR:

DENEB ROBLES GUILLÉN

MONTERREY , N.L. MAYO 2010

Instituto Tecnológico y de Estudios Superiores de Monterrey

Campus Monterrey

División de Mecatrónica y Tecnologías de Información

Programa de Graduados

Los miembros del comité de tesis recomendamos que la presente tesis del Ing. Deneb Robles Guillén sea aceptada como requisito parcial para obtener el grado académico de **Maestro en Ciencias,** especialidad en:

Automatización

Comité de tesis:

Dr. Luis Eduardo Garza Castañón
Asesor Principal

Dr. Rubén Morales Menéndez
Sinodal

Dra. Irma Yolanda Sánchez Chávez
Sinodal

Dr. Gerardo Antonio Castañón Ávila
Director de las Maestrías de Electrónica y Automatización de la DMTI

Mayo 2010

DIAGNÓSTICO DE FALLAS EN REDES ELÉCTRICAS INDUSTRIALES MEDIANTE REDES BAYESIANAS HÍBRIDAS

POR:

DENEB ROBLES GUILLÉN

TESIS

PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL GRADO ACADÉMICO DE:

MAESTRO EN CIENCIAS CON ESPECIALIDAD EN AUTOMATIZACIÓN

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY

MAYO 2010

Agradecimientos

"A mis padres…, ...por enseñarme el amor al estudio, responsabilidad, disciplina, apoyo incondicional que me han brindado, pero por sobre todo por hacerme la persona que soy ahora.

"Al Dr. Garza …, ...por su ejemplo de profesionalidad que nunca he olvidado, su guía, sus consejos y por creer en mí cuando ni yo lo hacía.

"A mis hermanas y familia ...por su fraternidad, cariño y comprensión en todo momento.

"A mis amigos, . ..por contribuir a mi empeño.

"A CONACYT,... ..por el apoyo económico brindado."

"A mis profesores, compañeros de trabajo, amigos...

...y todos aquellos que hicieron posible la confección y elaboración de este trabajo."

Resumen

En la actualidad las redes eléctricas se han convertido en una parte vital para el crecimiento económico, debido a su uso y alcance; aunado a esto, la importancia de un desarrollo sustentable a nivel mundial y la energía que puede ser perdida por diversas fallas en el sistema, que se ven transformadas en gastos para las empresas, ciudades y población en general, nos demuestran la necesidad de crear un sistema de soporte para la toma de decisiones en situaciones de falla. Por lo anterior, el objetivo principal de la Tesis realizada para la Maestría en Automatización, es la generación de una nueva estructura, basada en modelos gráficos probabilísticos híbridos, es decir, modelos que puedan trabajar simultáneamente con datos discretos y análogos, para realizar detección y diagnóstico de fallas simples y múltiples, en ambientes con ruido y pérdida de información en redes de distribución eléctrica industrial.

Para lograr el objetivo de la propuesta aquí mencionada, se realizaron simulaciones de fallas en redes eléctricas mediante el software MicroTran; extracción de rasgos característicos de los estados de operación normal y en modo de fallas; síntesis de los modelos probabilísticos híbridos a partir de los datos obtenidos en las simulaciones con ayuda del software Hugin Expert 7.0 y experimentación en diferentes escenarios con fallas simples y múltiples, del tipo simétricas y asimétricas.

El resultado obtenido fueron diversos modelos de dos etapas para diagnóstico de fallas, en donde la primera etapa consiste en la extracción de rasgos característicos de la información de la red eléctrica y la segunda propiamente en el modelo probabilístico que detecta e identifica la falla del sistema; de éstos, 3 modelos destacan por un desempeño superior a los demás. Mientras que la segunda etapa para estos 3 modelos fue realizada mediante Redes Bayesianas Híbridas; la primera etapa difiere en la utilización de técnicas como generación de índices de voltajes de 3 fases no balanceados, optimización de enjambre de partículas y teoría de onduletas.

Se concluye que para la red eléctrica industrial aplicada para este estudio, el modelo que combina la teoría de onduletas y Redes Bayesianas Híbridas presenta el porcentaje más alto de correcto diagnóstico de escenarios con fallas, bajo las condiciones previamente mencionadas.

Como conclusión general principal se tiene que, en vista de los resultados obtenidos, la aplicabilidad de modelos probabilísticos híbridos para la detección de fallas en procesos con alto nivel de incertidumbre y grandes cantidades de información, es posible, y que hoy en día, es parcialmente ventajosa respecto a otras soluciones consideradas tradicionales.

Por último, se mencionan las contribuciones principales de este trabajo:

- Una nueva estructura de detección y diagnóstico de fallas múltiples de redes eléctricas basada en modelos gráficos probabilísticos híbridos.

- La apertura de una línea de investigación en detección de fallas en procesos complejos con modelos probabilísticos híbridos, que pueden ser aplicables a sistemas industriales en general; ésto debido a que la estructura del modelo es flexible, por lo que puede ser modificada y adaptada a diversos procesos basada en el análisis de un historial de datos confiables.

Tabla de Contenidos

Agradecimientos……....*i*
Resumen……...*ii*
Tabla de Contenidos……....*iii*
Lista de Figuras…….…..*vi*
Lista de Tablas……...*viii*

CAPÍTULO 1: Introducción 1
1.1 Generalidades y Motivación 1
1.2 Estado del Arte 2
1.2.1 Redes Bayesianas para la Detección y Diagnóstico de Fallas 2
1.2.2 Detección y diagnóstico de fallas en Sistemas de Potencia 9
1.3 La propuesta 17
1.3.1 El objetivo 17
1.3.2 Estrategias conceptuales 18
1.3.3 Definición de estrategia 18
1.3.4 Red Eléctrica Industrial de Aplicación 20
1.4 Contribuciones de la Tesis 21
1.5 Organización de la Tesis 22
CAPÍTULO 2: PRIMERA PARTE: Metodología propuesta 24
2.1 Marco Teórico 24
2.1.1 Detección y diagnóstico de fallas 24
2.1.2 Redes Bayesianas 25
2.1.3 Redes Bayesianas Híbridas 27
2.1.4 Métodos de detección de fallas en Sistemas de Potencia 30
2.1.5 Software MicroTran 31
2.1.6 Software HUGIN EXPERT 7.0 32
CAPÍTULO 3: Experimentos 34
3.1 Sinopsis 34
3.2 Extracción de Rasgos Característicos de la señal: Acondicionamiento de señal 34
3.2.1 Ejemplo 36
3.2.2 Análisis de índices 37
3.3 Modelos probabilísticos híbridos: RBH 40

3.3.1 Primer modelo: Descripción 40
3.3.2 Evaluación Primer Modelo 42
3.3.3 Segundo Modelo: Descripción 43
3.3.4 Tercer Modelo: Descripción 43
3.3.5 Evaluación Tercer Modelo 44
3.3.6 Cuarto Modelo: Descripción 45
3.3.7 Evaluación Cuarto Modelo 46
3.3.8 Quinto Modelo: Descripción 47
3.3.9 Evaluación Quinto Modelo 48
3.3.10 Sexto Modelo: Descripción 49
3.3.11 Evaluación Sexto Modelo 51
3.3.12 Séptimo Modelo: Descripción 51
3.3.13 Evaluación Séptimo Modelo 53
3.3.14 Octavo Modelo: Descripción 54
3.3.15 Evaluación Octavo Modelo 54
3.3.16 Otros Modelos 55
CAPÍTULO 4: Resultados 57
4.1 Sinopsis 57
4.2 Modelo de la red eléctrica completa 57
4.3 Pruebas y Resultados 58
4.4 Comparación con otras estrategias existentes 60
CAPÍTULO 5: SEGUNDA PARTE: Optimización de enjambre de partículas (PSO) 65
5.1 Sinopsis 65
5.2 Optimización por Enjambre de Partículas (PSO) 65
5.3 Comparación con otras técnicas de computación evolucionadas 67
5.4 Variantes del PSO 68
5.5 Noveno Modelo: Descripción 68
5.6 Pruebas y Resultados 70
CAPÍTULO 6: TERCERA PARTE: Análisis de datos: Teoría de onduletas (Wavelets) 73
6.1 Sinopsis 73
6.2 Transformada de Fourier vs. Ondeletas 73
6.3 La Transformada de la Onduleta Continua 75
6.4 Onduletas Discretas 78
6.5 La Transformada de Onduleta Discreta (DWT) 79
6.6 Aplicación de la DWT en el proyecto de investigación 83

6.7 Décimo modelo: Descripción 87
6.8 Evaluación Décimo Modelo 89
CAPÍTULO 7: Resultados 91
7.1 Sinopsis 91
7.2 Modelo de la red eléctrica completa 91
7.3 Pruebas y resultados en condiciones ideales 92
7.4 Pruebas y resultados en condiciones no-ideales y presencia de ruido 100
CAPÍTULO 8: Conclusiones 103
8.1 Puntos fuertes del modelo 103
8.2 Limitaciones 104
8.3 Trabajo Futuro 104
Apéndice A: Parámetros de la red de IEEE 106
Apéndice B: Medias y Varianzas de los nodos sin ser tratados 109
Apéndice C: Índices de Falla 111
Apéndice D: Escenarios de falla para la red eléctrica de la IEEE 115
Apéndice E: Algoritmo para optimización de valores mediante el PSO 119
Apéndice F: Algoritmo para Extracción de Rasgos Característicos mediante Teoría de Onduletas 126
Bibliografía 128
Vita 136

Lista de Figuras

Figura 1: Red eléctrica industrial de pruebas. *IEEE Reliability Test System.* 3
Figura 2: Muestra de línea 14
Figura 3: Modelo de falla de línea 14
Figura 4: Esquema general detección de fallas 19
Figura 5: (a) Funcionamiento normal de las 3 fases de un nodo de la red eléctrica, (b) Falla tipo línea a línea (fase A y B), (c) Falla de tipo 1 fase a tierra (A-Gnd) 22
Figura 6: Programa mtPlot del software MicroTran 33
Figura 7: Modelo de RBH en HUGIN 33
Figura 8: Índices de fallas en Nodo 1 36
Figura 9: Falla Línea a Línea en Nodo 7 38
Figura 10: Primera estructura de RBH para la red eléctrica establecida 41
Figura 11: Corrección en parte digital del primer modelo 43
Figura 12: Tercera estructura de RBH para la red eléctrica establecida 44
Figura 13: Cuarta Estructura de RBH para la red eléctrica establecida 46
Figura 14: Quinta Estructura de RBH para la red eléctrica establecida 48
Figura 15: Sexta Estructura de RBH para la red eléctrica establecida 50
Figura 16: Séptima Estructura de RBH para la red eléctrica establecida 52
Figura 17: Octava Estructura de RBH para la red eléctrica establecida 54
Figura 18: Estructura de RBH para la red eléctrica establecida 56
Figura 19: Estructura de RBH para la red eléctrica establecida 56
Figura 20: Estructura completa de RBH para la red eléctrica establecida 58
Figura 21: Gráfica de evaluación 1 por nodo 61
Figura 22: Gráfica de evaluación 1 por tipo de falla 62
Figura 23: Gráfica de evaluación 2 por nodo 63
Figura 24: Gráfica de evaluación 2 por tipo de falla 64
Figura 25: Concepto de la modificación de búsqueda de punto por PSO 66
Figura 26: Diagrama de flujo de algoritmo PSO 68
Figura 27: Gráfica de evaluación 2 por tipo de falla 71
Figura 28: Gráfica de evaluación 2 por nodo 72
Figura 29: Transforma de Fourier de la función *x(t)=cos(2*π*5*t)+cos(2*π*10*t)+cos(2*π*20*t)+cos(2*π*50*t)* 74
Figura 30: STFT vs. Onduletas [74] 75
Figura 31: Señal coseno a diferentes escalas 77
Figura 32: Uso de la función escalada [73] 79
Figura 33: Técnica de submuestreo 80
Figura 34: Técnica de sobremuestreo 80
Figura 35: Proceso de descomposición de señal 82
Figura 36: (a) Imagen original “Barbara”; (b) Descomposición de imagen a través de DWT 83
Figura 37: Onduletas de la fase A del nodo 3 84
Figura 38: Onduletas fase A del nodo 3 con falla A-Gnd 85
Figura 39: Décima estructura de RBH para la red eléctrica establecida 88
Figura 40: Estructura completa de RBH con modelo 10 para la red eléctrica establecida 92
Figura 41: Gráfica de comparación por número de fallas 94

Figura 42: Gráfica de comparación por tipo de falla 95
Figura 43: Gráfica de evaluación 2 por tipo de falla 97
Figura 44: Gráfica de evaluación 2 por nodo 97
Figura 45: Gráfica de evaluación 3 por tipo de falla 98
Figura 46: Gráfica de evaluación 3 por nodo 98

Lista de Tablas

Tabla 1: Resumen estado del arte de sección 1.2.1 8
Tabla 2: Resumen del estado del arte de sección 1.2.2 16
Tabla 3: Índices de falla para el nodo 1 37
Tabla 4: Análisis de índices con reacción en cadena entre Nodo 3 y Nodo 24 39
Tabla 5: Relación de índices con reacción en cadena en Nodo 9 dado fallas en Nodo 10,11 y 12 .. 39
Tabla 6: TPC de la fase A del Nodo 1 41
Tabla 7: TPC del Nodo *"Nodo1 3 fases"* 45
Tabla 8: TPC del Nodo *"Nodo 1"* 49
Tabla 9: TPC del Nodo *"Nodo 1"* 50
Tabla 10: TPC del Nodo *"Breakers"* 52
Tabla 11: TPC del Nodo *"Breakers"* 53
Tabla 12: Porcentaje de eficiencia del modelo propuesto 59
Tabla 13: Porcentaje de eficiencia por tipo de falla 59
Tabla 14: Evaluación 1 por tipo de falla 61
Tabla 15: Evaluación 1 por nodo 61
Tabla 16: Evaluación 2 por tipo de falla 62
Tabla 17: Evaluación 2 por nodo 62
Tabla 18: Pesos para calcular índice de fallas obtenidos con PSO 69
Tabla 19: Comparación de evaluación 2 por tipo de falla 71
Tabla 20: Comparación de evaluación 2 por nodo 71
Tabla 21: Patrones de coeficientes obtenidos por DWT en el nodo 1 86
Tabla 22: Tabla condicional probabilística de la fase A del Nodo 3 88
Tabla 23: Tabla condicional probabilística de la fase B del Nodo 3 88
Tabla 24: Tabla condicional probabilística de la fase C del Nodo 3 88
Tabla 25: Únicas posibles combinaciones para determinar tipo de falla presentada 89
Tabla 26: Porcentaje de eficiencia en primera evaluación 93
Tabla 27: Porcentaje de eficiencia por tipo de falla 93
Tabla 28: Evaluación 2 por tipo de falla 95
Tabla 29: Evaluación 2 por nodo 95
Tabla 30: Evaluación 3 por tipo de falla 96
Tabla 31: Evaluación 3 por nodo 96
Tabla 32: Porcentaje de Eficiencia por tipo de falla 99
Tabla 33: Porcentaje de Eficiencia por número de nodo 99
Tabla 34: Porcentaje de eficiencia en primera evaluación 100
Tabla 35: Evaluación 2 por nodo 101
Tabla 36: Evaluación 3 por nodo 102

Tabla A 1: Cargas en la red de potencia de IEEE 107
Tabla A 2: Impedancias de la red de potencia de la IEEE 108

Tabla B 1: Media y varianza de los nodos de la red eléctrica industrial, sin ser tratados. 110

Tabla C 1: Índices de Falla con método basado en [58]. 112
Tabla C 2: Índices de Falla con PSO. 113
Tabla C 3: Índices de Falla con Teoría de Ondeletas. 114

Tabla D 1:Escenarios de Falla para la red eléctrica de la IEEE 116
Tabla D 2: Simulaciones de escenarios de falla para evaluación 1 117
Tabla D 3: Simulaciones de escenarios de falla para evaluación 2 118

CAPÍTULO 1
Introducción

1.1 Generalidades y Motivación

La electricidad hoy en día, más que ser solamente un factor de comodidad y de status social, se ha convertido en un factor vital para el desarrollo de economías y estabilidad en un país, al ser un instrumento que es utilizado en fábricas, casas-hogar, hospitales, entre otros. El consumismo y el nivel de vida al que se han acostumbrado las personas han tenido repercusiones en todos los ámbitos, siendo la demanda de electricidad uno de ellos; ya que se ha necesitado de mayores cantidades de su producción principalmente en la industria, lo cual nos lleva a sistemas más complejos para su elaboración y uso, mayor número de dispositivos utilizados, técnicas más sofisticadas y una adquisición de mayor cantidad de datos. Como consecuencia, se tiene un escenario donde se torna difícil el monitoreo de los procesos por parte de los operadores, especialmente en lo que concierne a la localización y aislamiento de las fallas de una manera rápida, segura y eficiente. Es por esto, que en los últimos años, diversos investigadores han desarrollado propuestas para realizar sistemas automatizados de detección y diagnóstico de fallas en redes eléctricas, que permiten asistir a los operadores en la toma de decisiones [1].

Las causas que ocasionan las fallas en las redes eléctricas son diversas y su aparición depende tanto de las condiciones bajo las que fueron instaladas, así como también del mantenimiento que se le ha dado a la red, los efectos ambientales, la vida útil de los dispositivos utilizados, interferencia externa, entre otras. De los anteriores, los efectos ambientales son una herramienta útil en el diagnóstico de fallas, debido a que redes eléctricas ubicadas en diferentes regiones geográficas, serán más propensas a presentar un cierto tipo de fallas. Un ejemplo de esto, es que en el norte del país, las redes eléctricas son más propensas a presentar fallas de una o varias fases a tierra por motivos de viento y poca humedad.

Las consecuencias que acarrean las fallas en una red eléctrica consisten principalmente en afectaciones económicas, energéticas y de seguridad para el personal y los equipos. Un suministro de voltaje o corriente insuficiente, trae como consecuencia directa el malfuncionamiento de las máquinas, productos con especificaciones mecánicas por debajo del nivel requerido y por lo tanto, a un mayor consumo de energía para alcanzar las especificaciones establecidas, es decir, existe una pérdida energética, la cual se traduce en un aumento en el costo de producción. Los cortos circuitos, también pueden ocasionar incendios y averías de maquinaria, que en muchas ocasiones son costosas de reparar y peligrosas para los trabajadores. En Garza et al. [2] se comenta que una rápida detección y diagnóstico de fallas de una red eléctrica, que analice la información proveniente del sistema o proceso y determine si su operación es normal o de falla, ayudaría en la disminución de estos factores, ya que reduciría los tiempos muertos de producción o servicio y favorecería a la protección tanto de los seres humanos como de las instalaciones de la empresa.

Para prevenir estas fallas, las empresas han invertido en protección física (hardware) para el cableado que se tenga a la intemperie, así como también en dispositivos redundantes para regular y monitorear las variables de proceso; sin embargo, una vez que las fallas ocurren, son los métodos de detección de fallas los encargados de diagnosticar la red, y ahí radica su importancia.

Por todo lo anteriormente dicho, es necesario que se creen nuevas herramientas de detección y diagnóstico de fallas con los que se obtengan resultados con una eficiencia y robustez aceptable en el procesamiento de información en todo momento, inclusive en ambientes con falta de información y ruido en los datos. Estos nuevos sistemas de detección de fallas, deben tener la capacidad de manejar grandes cantidades de información tanto discreta como continua (conocidos como sistemas híbridos), así como también la capacidad de detección, aislamiento e identificación de fallas. Como un valor agregado los modelos desarrollados podrá ser aplicables a otras áreas de diagnóstico de fallas. Además, los datos aquí obtenidos podrán ser utilizados para propósitos de comparación, con otros algoritmos de detección y diagnóstico.

1.2 Estado del Arte

Se han propuesto diversas técnicas para el área de detección y diagnóstico de fallas para redes de distribución eléctrica. Debido a la complejidad de estos sistemas, los investigadores se han visto en la necesidad de combinar diferentes métodos, denominados métodos híbridos, para así poder realizar un proceso de diagnóstico eficiente. En las siguientes subsecciones, se describirán algunos de estos trabajos y los resultados que los investigadores obtuvieron.

1.2.1 Redes Bayesianas para la Detección y Diagnóstico de Fallas

Zhao et al. en [3] combina el método de Redes Bayesianas Dinámicas con el método MCMC (Markov Chain Monte Carlo), en una red industrial con un número considerable de dispositivos, los resultados son correctos, efectivos y tienen potencial para su aplicación en tiempo real. El trabajo más importante para esta propuesta, es el realizado como tesis doctoral por Garza [2], en donde se realiza un algoritmo de diagnóstico de 2 fases, probada en la red eléctrica mostrada en la Fig. 1. En donde en la primera fase se utilizan Redes Bayesianas para procesar la información discreta del sistema y en la segunda etapa se utilizan modelos dinámicos probabilísticos. Los resultados fueron aceptables, sin embargo, al tener un procesamiento de la información en 2 etapas, el diagnóstico se hace lento, y por lo tanto, se tienen problemas de eficiencia y robustez, en escenarios con falta de información y ruido en los datos.

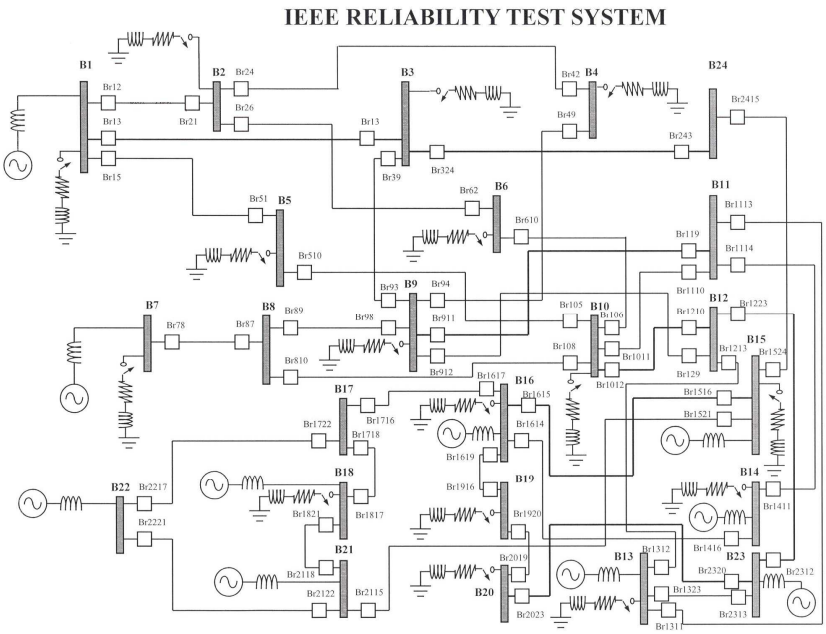

Figura 1: Red eléctrica industrial de pruebas. *IEEE Reliability Test System.*

En [4], una técnica selectiva Bayesiana es introducida para identificar un alimentador con falla en una red de medio voltaje compensado (MV). La técnica propuesta se basa en un método probabilístico condicional aplicado en características extraídas de las corrientes residuales utilizando solamente la transformada de la onduleta discreta (DWT). DWT realza la localización inicial de los transitorios generados en la red debido a un evento de falla. La suma absoluta de la ventana del coeficiente detallado de DWT es utilizado para detectar la falla. La probabilidad condicional provee la decisión selectiva. Los casos de falla (resistivas y fallas en al arco) ocurriendo en localizaciones diferentes en una red compensada de 20 kV con una distribución de 5 alimentadores, son simulados por ATP/EMTP. La eficacia del método es demostrada, sin embargo se tiene un límite de sensibilidad de 1.5 kΩ de resistencia de falla.

Las Redes Bayesianas también son capaces de modelar los procesos de fundición como una constelación probabilística de variables interrelacionadas, como se propone y realiza en el documento [5]. De esta manera, después de un proceso de aprendizaje adecuado, la Red Bayesiana es capaz de inferir las relaciones causales; en otras palabras, puede adivinar el valor de la variable (por ejemplo, la presencia o no de una falla). En [5], se presenta el primer sistema de predicción de micro-encogimiento o micro-contracción que, basado en las Redes Bayesianas, es capaz de predecir la aparición de este defecto con el objeto de evitarlo. Se realizaron 3 experimentos con diversas piezas en 2 procesos de fundición. Los resultados demuestran que la reducción de la aparición de este defecto, puede ser de hasta 95%.

En [6] se presenta una investigación de un sistema de monitoreo y diagnóstico de paneles de bajo voltaje basados en mediciones de corrientes, temperaturas del ambiente y temperaturas locales de uniones eléctricas. El sistema necesita la prevención de cortos en los paneles de bajo voltaje, los cuáles, aunque raros, pueden involucrar grandes pérdidas

financieras y humanas. Las mediciones térmicas son hechas vía sensores de temperatura inalámbricos. La información medida es transmitida vía internet y recolectada en un servidor, que será centralmente procesado. Este procesamiento de información centralizada incluye una detección local de malfuncionamientos y un diagnóstico global que lleva a algunas recomendaciones de mantenimiento. El método propuesto en [6], se enfoca en la detección local de fallas mediante la comparación de un modelo sano y un diagnóstico global utilizando la técnica de Redes Bayesianas. La implementación concreta de una parte del panel en una Red Bayesiana demuestra que este método puede ser utilizado como una herramienta útil para el diagnóstico y el análisis de riesgos también, y una ventaja adicional de esta técnica es que permite utilizar la experiencia de la retroalimentación para actualizar las probabilidades condicionales con el proceso de aprendizaje.

En [7] se discute principalmente sobre cómo emplear la teoría Bayesiana para realizar un diagnóstico de fallas. Se demuestra que la aplicación de la teoría Bayesiana, combinada con el modelo OR-Ruidoso, ayuda a reducir la cantidad de información requerida, mejorando la velocidad y eficiencia del diagnóstico. El modelo propuesto en [7] para el análisis del sistema de sellado del petróleo en los turbo generadores, es probado en una estructura de red de 3 niveles basada en condiciones prácticas, así como síntomas. Del modelo se obtienen diagnósticos exitosos, con exactitud mejorada por la implementación del modelo OR-Ruidoso.

En un proceso que combina el calor y la generación de potencia se necesita de detección de fallas, ayuda en la toma de decisiones y evaluación de riesgos para prevenir perturbaciones operacionales y reducción en su desempeño. La Red Bayesiana cubre los super-calentadores convencionales en el tren de gas, el cual es un problema mayor en el dominio de las calderas de biomasa. El depósito de cenizas que se obtiene en el super-calentador reduce la velocidad de transferencia y da como resultado un decremento en el desempeño de la planta de potencia. En [8], la Red Bayesiana (RB) es construida para dar soporte en la toma de decisiones en acciones preventivas para reducir la contaminación anormal. La red probada consiste de 5 boilers de los cuáles el número 5 produce vapor de 540°C y 173 bar y genera 45 MW de potencia eléctrica y al mismo tiempo produce 100 MW de calentamiento. El boiler 5 y otro más antiguo son conectados a la misma turbina de vapor. La RB es utilizada como un soporte en la toma de decisiones de la generación de hollín basado en la predicción de la generación de la contaminación. En lugar de realizar la toma de decisión de una manera manual con la medición del vapor de las temperaturas como entrada única, la decisión se realiza de un número de propiedades operacionales en combinación con la experiencia. Las pruebas revelan que la RB es capaz de predecir la generación de la contaminación baja y alta. También es posible utilizar la Red para evaluar diferentes mezclas de propiedades de combustibles para evitar ciertas mezclas, que elevan el riesgo de la generación de la contaminación.

En [9], un conjunto de redes neuronales artificiales (ANNs) son entrenadas para modelar varios modos de falla conocidos del sistema, además del modelado de su operación normal. El modelo ANN es compuesto de un único perceptrón en una capa (SLP) en cascada con un filtro de respuesta de impulso infinito (IIR). En este trabajo, se utiliza el método de aproximación estocástica de perturbaciones simultáneas (SPSA). Una vez que un conjunto de redes han sido entrenadas, la detección de fallas es lograda

mediante el arreglo de éstas en paralelo con un sistema real, y comparando las salidas de cada red con salidas del sistema medido para obtener la señal residual. El residual es aleatorio porque las salidas del sistema incluyen ruido en las mediciones en la práctica. Se modela la señal residual utilizando Redes Bayesianas Dinámicas (DBN) en donde una cadena discreta de Markov representa el comportamiento aleatorio del sistema. El método aquí propuesto, se aplicó a un sistema de control de un motor de inducción en tiempo real. Tres motores de inducción con las mismas especificaciones son utilizados, de los cuáles uno está sano, otro tiene un estator defectuoso y el otro tiene un balero defectuoso. Al realizar pruebas en los tres motores, se concluye que dos de los motores están operando anormalmente por lo que el algoritmo propuesto se desempeña de manera exitosa y cumple el fin establecido.

La percepción en los sistemas omnipresentes están basadas en las lecturas de los sensores y dispositivos. El sistema decide proveer servicios adecuados basados en estas lecturas. En [10], se define un sistema de detección de fallas en el mecanismo de percepción de un sistema omnipresente basado en Redes Bayesianas y la combinación de creencias de redes independientes. La técnica utiliza el conocimiento a priori que el sistema posee como lo son las preferencias del usuario y descripciones de sensores y dispositivos. Las RB son creadas por cada posible ciclo de interacción con la suposición que incluso con nodos sobrepuestos las Redes son mutuamente independientes y la réplica del dispositivo en estos escenarios es usado para formar una creencia global acerca del estado del dispositivo o sensor. La prueba de este algoritmo se realizó en un solo escenario en donde la temperatura del sensor estaba equivocada. El esquema propuesto no sólo ayuda en el filtro de percepciones de falla sino también que forma un componente vital necesario para la creación de un sistema más autónomo, especialmente en el caso en el que se requiere auto-corrección y auto-optimización.

En [11], se propone un modelo híbrido el cual consiste de un modelo de diagnóstico de fallas multi-capas adecuada para manejar varios tipos de fallas en todos los niveles de granularidad en redes computacionales. El modelo de diagnóstico no solamente provee el proceso de detección automatizado, colección de alarmas y correlación, sino también tiene la función de discriminación de falla eficiente. El modelo de capas es mapeado a un detector en línea, un correlacionador probabilístico y un razonador basado en casos. La aplicación de las redes de creencias permite una representación flexible del conocimiento. Un nuevo algoritmo de recuperación para discriminación y perfilado de fallas es propuesto, el cual procesa síntomas incrementales mientras son recibidos, y muestran a través de la simulación que este algoritmo es rápido computacionalmente, haciéndolo escalable a redes muchos más grandes que otros algoritmos. El algoritmo es capaz de identificar fallas múltiples y simultáneas.

Las Redes Bayesianas Dinámicas son propuestas en [12] para modelar dependencias estáticas y dinámicas entre los objetos manejados en una red de protocolo de internet (IP). Las estrategias de predicción y la propuesta de inferencia hacia atrás son previstas para el manejo proactivo en la detección de fallas basado en los cambios dinámicos de las redes IP. Para modelar cambios dinámicos en un sistema de redes, extensiones temporales de las RBs son empleadas para integrar la dimensión de tiempo y para presentar las estrategias de predicción basadas en la inferencia hacia atrás en el manejo de fallas en un ambiente dinámico de sistemas de redes. En otras palabras, las RBs son utilizadas para representar

el conocimiento acerca de los objetos manejados y sus dependencias y aplicar razonamiento probabilísticos para determinar las causas de los errores o malfunciones. No solamente son consideradas las predicciones de fallas de una entidad individual y la relación de dependencia entre las entidades manejadas, sino también la detección potencial de la falla de los efectos a las causas en las RBs son investigadas. Cuando el sistema no puede dar una localización de la falla exacta, la inferencia relacionada y la propuesta de predicción puede actuar como un mecanismo efectivo en el diagnóstico, jerarquizando posibles fallas, manejando fallas simultáneas múltiples, y robustez mediante el razonamiento probabilístico y demostrar una detección de fallas más óptima que la detección aleatoria o exhaustiva.

En [13], se habla sobre las diferentes herramientas que ofrece el software FUMS^{TM}, el cual es una herramienta utilizada para el diagnóstico, pronóstico y el enfoque de gestión de vida útil que es dirigida a empresas de aeronaves. Las aplicaciones de fusión FUMS^{TM} contienen herramientas de procesamiento de señales convencionales y avanzadas. Las herramientas incluyen un conjunto de herramientas de análisis estadístico, herramientas de conteo de ciclos, descomposición del valor singular (SVD), análisis de componentes principales (PCA) y redes neuronales artificiales (ANN) para el análisis no-lineal multivariante. También incluye un conjunto de herramientas de inteligencia artificial (AI) como redes neuronales, Redes Bayesianas, lógica difusa, algoritmos genéticos y redes matemáticas. Aunque el texto se enfoca más sobre las teorías de lógica difusa, las RBs son mencionadas como una técnica de detección de fallas, la cuál es probada mediante la identificación de datos corruptos en la información obtenida de ciertos vuelos, obteniendo resultados exitosos.

En [14] se realiza un algoritmo para detección de fallas a través del procesamiento y análisis de residuales, para el sistema de control vehicular. El método incorpora residuales de modelos múltiples usando una Red Bayesiana Híbrida Dinámica para entregar un sistema de diagnóstico de bajo-costo y completo. Los residuales continuos son utilizados como evidencia directa en la red. La RB es utilizada para modelar el comportamiento temporal de las fallas, y las asunciones necesarias para ser analizadas. El método desarrollado fue probado, teniendo como entrada 6 sensores localizados en un vehículo, y se simularon diez fallas, que podían ser algún desperfecto físico en las llantas o una falla en el sensor de la velocidad de las llantas o el ángulo de dirección. El modelo detectó y aisló correctamente ambas fallas, a pesar de su corto tiempo de duración, también se habla sobre una posible mejoría si se utilizaran distribuciones probabilísticas diferentes a la distribución normal.

En [15], se comparan diferentes técnicas de inferencia y se muestra que es posible realizar inferencias en un una compleja Red Bayesiana Híbrida inámica. La DBN Híbrida modela la detección de fallas en un sistema de tanques de agua, consistente de seis variables de falla de las tuberías y tres variables de falla de mediciones. Para el sistema de inferencia, se utiliza un filtro de partículas genéricas (PF) y para la inferencia aproximada un filtro de Kalman (EKF) y el filtro extendido de Kalman (UKF). En [15] se utiliza un modelo estacionario y dinámico, en donde los nodos dados en el tiempo t son dependientes de las variables en el tiempo t y $t-1$. Esto permite que las relaciones entre las variables varíen con el tiempo. Se presenta un modelo que posee tanto datos discretos como continuos y relaciones lineales y no lineales. Se demuestra con el trabajo que una diferente

estructura de la Red puede mejorar la exactitud del PF y el uso del UKF mejora la habilidad de rastreo de la falla en los nodos y estima las variables de estado continuo con un número bajo de muestras. Aunque en [15], se da más enfoque en los métodos de inferencia de la RB, se puede observar cómo es que la Red es utilizada con el fin de la detección de fallas, y como ésta es mejorada, a través de diferentes métodos de cálculo de inferencia.

En [16], se propone un modelo híbrido de propagación de fallas para la detección de fallas, el cual incluye un modelo multi-capas FPM (modelo de partición difusa) y un modelo de dos-capas FPM. El proceso de diagnóstico es dividido en 2 procedimientos: servicios de aplicación y de redes al diagnóstico de fallas. Como la observación de las fallas es incierta, se mapea el modelo del diagnóstico de fallas a una Red Bayesiana para realizar el razonamiento incierto. Para mejorar la velocidad de inferencia, se anexa un algoritmo de eliminación de cubeta (bucket elimination) con mínima deficiencia para tener un mejor orden. Las pruebas son realizadas en una red con 32 nodos de computadoras, 2 nodos de administración y 4T SAN (red de área de almacenamiento de 4 Terabytes) de almacenamiento. Los experimentos demuestran que es viable utilizar modelos de detección híbridos para los sistemas de aplicaciones distribuidas y algoritmos exactos para la inferencia. El algoritmo consume una gran cantidad de memoria, por lo que aumentar el tamaño de memoria de una computadora es una solución.

Desarrollar un agente de diagnóstico descentralizado y autónomo el cual observe un proceso técnico que actualice dinámicamente un modelo interno probabilístico de fallas, es presentado en [17]. El modelo es una DBN que puede razonar bajo incertidumbres acerca de causas de fallas de los eventos que son monitoreados. El enfoque se centra en establecer el ciclo de diagnóstico en dos maneras independientes: primero, los agentes autónomos diagnostican aparatos de altas-consecuencias de un sistema modular de manufactura y segundo, información confiable a priori necesaria es derivada de un programa de aseguramiento de calidad. La Red Bayesiana Dinámica, a partir de la evidencia de las observaciones de los sensores, es capaz de aprender y razonar con el tiempo. La técnica de diagnóstico presentada, fue probada exitosamente en una aplicación específica del dominio de un sistema mecánico-neumático, en donde se realizaban fallas abruptas en la presión y uno de los pistones.

En [18] se propone un algoritmo de fusión multi-sensor Bayesiano, eficiente en línea e híbrido para el rastreo de objetivos en la presencia de fallas modeladas y no modeladas. El algoritmo está dividido en dos etapas, en la primera se remueve las fallas modeladas de cada estimado individual del sensor y en la segunda se le resta importancia a las estimaciones que han sido objeto de fallas imprevistas y todavía presentan datos erróneos, a pesar de haber sido sometidos al proceso de recuperación de fallas de la etapa 1. El algoritmo es probado en 2 escenarios simulados que contienen 5 mediciones de sensores, en donde en el primer escenario el modelo del proceso de rastreo no coincide con la realidad y en el segundo, existe la presencia simultánea de fallas modeladas y no modeladas. Los resultados obtenidos son exitosos, siendo el enfoque de manera modular y descentralizable, así como muy eficiente en términos computacionales mientras realiza la recuperación ante fallas en cada sensor individual.

Autor	*Método*	*Modelo estudiado*	*Fallas detectadas*
Garza [2]	RB con ANN	Red eléctrica industrial de 24 nodos.	Línea a línea y una, dos y tres fases a tierra.
Zhao et al. [3]	DBN con MCMC	Red industrial con 24 componentes.	28 tipos de fallas.
Elkalashy et al. [4]	Técnica selectiva Bayesiana con DWT	Diagrama de una sola línea de transmisión.	Fallas resistivas y de medición de arco en voltajes.
Penya et al. [5]	RB	2 procesos de fundición.	Predicción de aparición de micro-encogimiento.
N'guessan et al. [6]	RB	Paneles de voltajes bajos.	Diagnóstico global del panel.
Tian et al. [7]	Teoría Bayesiana con modelo OR-Ruidoso	Sistema de sellado del petróleo en los turbo generadores.	Fuga de aceite, hidrógeno y contaminación en el hidrógeno.
Widarsson et al. [8]	RB	Super-calentadores convencionales en el tren de gas. Específicamente, planta de 5 boilers.	3 diferentes niveles de suciedad (cenizas) en los boilers. Predicción de generación de suciedad blanda y dura.
Cho et al. [9]	ANN con DBN	Sistema de control de un motor de inducción en tiempo real.	Estator defectuoso, bobinado del estator en corto circuito, balero defectuoso.
Ahmed et al. [10]	RB y combinación de creencias de redes independientes	Sistema con aire acondicionado, sensor de temperatura interna y externa, detector de movimiento, sensor de humedad, humidificador, sensor de estudio de temperatura.	Sensor de temperatura interna defectuoso.
Ali et al. [11]	BN con técnicas de razonamiento basada en casos	Red de área local con 6 nodos pre-configurados, 3 nodos móviles y una estación de base.	Nodo móvil fuera de rango y congestión en un punto de acceso.
Jianguo et al. [12]	DBN	Redes IP.	Detección de fallas basada en cambios dinámicos.
Wakefield et al. [13]	RB	Software FUMS™ en aeronaves.	Identificación de datos corruptos en la información.
Schwall et al. [14]	RBHD con análisis de residuales	Sistema de manejo de un automóvil, consistente de 6 sensores: 4 sensores de velocidad en las ruedas, 1 en la orientación de giro y 1 en el ángulo de dirección.	Fallas en cualquiera de los 6 sensores y además fallas físicas en cualquier llanta.
Andersen et al. [15]	Sistemas de inferencia en RBHD	Sistema de tanques de agua, consistente de 6 variables de falla de las tuberías y 3 variables de falla de mediciones.	Error de medición, explosión de una tubería, incremento o decremento de la resistencia de la tubería.
Yunchun et al. [16]	RB con FPM	Computadora Inspur TS10000, con 32 nodos de cómputo, 2 nodos de administración y 4T de almacenamiento.	Diagnóstico de red.
Lauber et al. [17]	DBN	Sistema modular de manufactura: válvula de control de flujo unidireccional, de retención, de control de flujo, de 4/2, tubería y cilindro de doble efecto.	Fallas abruptas: disminución de presión.
Reece et al. [18]	Algoritmo de fusión multi-sensor Bayesiano	El sistema consiste de 5 sensores.	Fallas modeladas y no-modeladas.

Tabla 1: Resumen estado del arte de sección 1.2.1

1.2.2 Detección y diagnóstico de fallas en Sistemas de Potencia

En [19] se habla sobre la detección de fallas en sistemas de potencia, mediante la medición de las señales de voltajes y corrientes por el relevador, las cuales son pre-procesadas utilizando la transformada de onduleta (WT) con el único fin de detectar perturbaciones debidas a la propagación de ondas-viajeras. El PCA (análisis de componentes principales) es utilizado para proveer una descripción compacta de las ondas que llegan al relevador a través de la aplicación de la información extraída por la WT a diferentes escalas. El algoritmo propuesto utiliza la polaridad, magnitud e intervalo de tiempo entre las ondas-viajeras detectadas, y puede identificar fallas internas rápidamente. El algoritmo en [19] es probado en una línea de transmisión de 400 kV. Todas las fallas son identificadas en altos voltajes, sin embargo, el problema principal de las técnicas basadas en ondas-viajeras, es que a pequeñas magnitudes de voltajes, las ondas generadas también son pequeñas, siendo a veces un poco difícil para el esquema localizar ciertas fallas. Es por eso, que en [19] se propone un algoritmo adicional para la detección de éstas, basado en relevadores de sobre-corriente e impedancias. Cabe mencionar que esta técnica tiene alta inmunidad al ruido, y no necesita una gran cantidad de datos para ser entrenada.

En [20] un nuevo algoritmo para la localización de fallas en líneas de transmisión es presentado. La técnica utiliza la unidad de medición de fasores (PMU, por sus siglas en inglés), en donde la localización de la falla es adicionada al estimador de estado basado en PMU como una nueva habilidad. Si una falla de corto circuito ocurre, entonces la falla puede ser detectada utilizando la habilidad de identificación de información corrupta en la estimación del estado. Entonces el vector y la matriz Jacobiana es producida. En el nuevo estado del vector, la localización y el voltaje de falla son adicionados como un nuevo estado de la variable. Finalmente, la localización es estimada así también como otros estados de variables. Este método solo puede ser utilizado en el caso en que dos PMUs sean instalados en dos terminales de la línea de transmisión. El algoritmo fue probado y validado en una red de potencia con 6 nodos, obteniendo resultados exitosos.

En [21] se presenta un sistema de medición de corriente y voltaje basado en fibra óptica para una distribución de líneas de alto voltaje. El sistema convencional de detección de fallas es sustituido por método de detección de fallas basado en fibra óptica (sensores FBG, los cuáles son un tipo de reflector Bragg distribuido) debido a que éstos permiten la fácil multiplexión de varias señales de falla en el sistema. Para que sea económicamente factible, el uso de transmisores y receptores es eliminado. La tecnología PLC/SCADA es utilizada en la subestación para recibir y transmitir datos. Tres sensores son instalados en cada fase de la línea de transmisión, para probar su eficiencia. Los resultados son exitosos, para la detección de fallas con alta impedancia y fallas causadas por conductores rotos en la línea de transmisión.

En [22] el método propuesto calcula la distancia de la falla basado en las señales muestreadas en una de las terminales de la línea de transmisión. La idea principal es que se utilice el intervalo de tiempo inherente entre los diferentes componentes modales de la señal de tres-fases de llegada para determinar la localización de la falla. Una vez que es determinada la localización de la falla aproximada, entonces la locación exacta de la falla

será calculada basada en la WT. Este método fue probado en una simulación de un sistema de transmisión de potencia de una mina de carbón, creando y detectando exitosamente, fallas de una sola fase a tierra.

Un sistema de protección posicional integrado basado en la detección de transitorios de falla es presentado en [23]. En donde un relevador de protección posicional central es instalado en la línea de transmisión de una subestación, a través de una unidad de interfaz especialmente diseñada para la comunicación de la red. Con este arreglo, el relevador integrado puede ser utilizado para la protección de todas las líneas de transmisión asociadas con la subestación. El relevador integrado detecta la falla generada de señal con transitorios de altas frecuencias y graba el instante de tiempo correspondiente a cuando la onda viajera inicial generada por la falla llega al nodo, por la línea de transmisión. El puerto de comunicación es utilizado para transmitir y recibir señales digitales codificadas de la información local de y para los relevadores asociados en el sistema. En cada subestación, los relevadores determinan la locación de la falta mediante la comparación de las llegadas sucesivas de los transitorios de fallas en la locación del relevador y el tiempo del GPS (sistema de posición global) con aquellos recibidos por las subestaciones vecinas. El método fue probado en un sistema de transmisión de potencia, basado en una línea vertical de 400 kV. Dos secciones de las líneas son modeladas con longitudes de 128 y 147 km, respectivamente, mostrando resultados satisfactorios.

A pesar de que la teoría de onduletas, es generalmente utilizada en combinación con otros métodos, esto no quiere decir que por sí sola no pueda dar un diagnóstico del estado de una línea de transmisión. En [24], la distancia actual donde la falla es creada es comparada con la distancia calculada utilizando la transformada de onduleta y el error entre estas dos mediciones sirve para posteriormente calcular su locación y clasificación. Pruebas realizadas para la validación de este método fueron realizadas en una simulación de una sola línea de transmisión de 500 kV con fallas en intervalos de distancia de 500 km, obteniendo un porcentaje de error en la localización de la falla de -10% a 13%, porcentaje que puede variar dependiendo del incremento o decremento de la resistencia de falla.

Después de que una falla ocurre en una línea de transmisión, diferentes tipos de fallas tienen diferentes niveles de complejas señales transitorias de voltaje que pueden ser medidas. Es por eso que en [25], la descomposición modal empírica (EMD) con entropía aproximada y mínimos cuadrados con máquinas de soporte vectorial (LS-SVM) con BCC (algoritmo de quimiotaxis de colonias bacterianas) fueron utilizados para detectar señales de falla en una fase a tierra, y después distinguir las fallas transitorias de las fallas permanentes en las líneas de transmisión. Analizando las características de las señales transitorias de voltaje, el EMD es utilizado para descomponerlas, después calcular la entropía aproximada de las funciones modales intrínsecas como los valores propios, el algoritmo BCC es utilizado para optimizar el LS-SVM. El método aquí explicado fue probado en una sola línea de transmisión con dos terminales, obteniendo resultados satisfactorios inclusive con un número pequeño de muestras.

Existen modelos de detección de fallas basados en algoritmos con mediciones en una sola terminal de la línea de transmisión o en ambas terminales, es por eso que en [26], ambos algoritmos fueron implementados en la sección de modelaje asociado a algunas redes de potencia con modelos ATP (Programa de alternativas transitorias). Los módulos de localización de fallas contienen filtros basados en DFT (transformada de Fourier

discreta) con procesamiento de los transitorios de voltajes y corrientes, módulos calculando los componentes positivos y cero de éstos y módulos calculando el índice de locación y el error. También, hay módulos utilizados para detectar la ocurrencia de falla y el tipo, los cuáles calculan la corriente de falla en el emisor final de la línea, como la diferencia entre la corriente total y la corriente almacenada de pre-falla. Los resultados presentados en ese trabajo fueron obtenidos utilizando un modelo ATP de un caso de dos máquinas de una red de 400 kV teniendo una sola línea de transmisión de 300 km. Como se podía predecir desde un principio, los resultados obtenidos con el algoritmo con mediciones en ambas terminales es más preciso que el de una sola terminal, siendo la notoriedad mayor en fallas con una fase a tierra y con una diferencia muy pequeña en casos con fallas multifase.

En [27], se habla sobre la integración de un pre-procesamiento de señales en tiempo real, basado en la teoría de las onduletas que permita una mejora en la capacidad de aprendizaje de la técnica SVM y el poder de clasificación en sistemas de transmisión de potencia. El criterio de clasificación se basa en la utilización de los ángulos de fase entre las tres líneas de corriente en la línea de transmisión, con límites de separación no-lineales entre los ángulos creados por el SVM durante el entrenamiento. Este algoritmo fue probado en un modelo de potencia de tres fases, con una sola línea de transmisión. Los resultados demostraron la viabilidad y exactitud del método propuesto.

En [28], la transformada discreta de la onduleta (DWT) es aplicada para el análisis de transitorios, por su habilidad para extraer información de la señal transitoria, simultáneamente en el dominio de tiempo y frecuencia. La información obtenida de la DWT es utilizada para entrenar y probar la arquitectura de la red neuronal artificial (ANN). El clasificador utilizado en este trabajo es un esquema de red neuronal con tres capas de propagación hacia atrás (Backpropagation). Las pruebas fueron realizadas en una sola línea de transmisión simulada, de 110 kV con 50 Hz de frecuencia con una distancia de separación entre las dos fuentes de 200 km. Los resultados demuestran que el esquema discrimina muy bien los transitorios correspondientes a cada una de las fallas en una manera muy clara, así también el esquema presenta una exactitud del 93.89% en 923 iteraciones, que puede ser mayor, si la ANN es mejorada.

En [29], se presenta una lógica eficiente y rápida para hardware para la detección y clasificación de fallas en las líneas de transmisión utilizando FPGA (siglas en inglés de Field-Programmable Gate Array). El FPGA de propósito general denominado SPARTAN3E fue utilizado para desarrollar el prototipo, con todo el código utilizando un lenguaje de descripción de hardware (HDL) denominado circuito integrado de velocidad muy rápida (VHDL). El método utilizado propone utilizar sólo las corrientes muestreadas de una terminal y está basado en el análisis de onduletas. La clasificación de las fallas se hace en un tiempo de 6 ms, el cual es cerca de 1/3 del ciclo de frecuencia (20 ms). Un nivel alto de eficiencia computacional es alcanzado en comparación con los otros algoritmos basados en onduletas, debido a que solamente se utiliza el primer nivel de alta frecuencia en este algoritmo. El método propuesto es probado en una sola línea de transmisión de 400 kV con 4 buses, simulando fallas simples y simultáneas. Los resultados demuestran que aunque algunas veces las fallas de doble fase a línea son mal clasificadas, se puede esperar que todo el método en general tenga una exactitud de 99.53%

En [30], la aplicación de un sistema de inferencia adaptivo neuro-difuso (ANFIS) para la protección de relevadores a distancia para una línea de transmisión en un sistema eléctrico de potencia (EPS) es presentado. La técnica se especializa en el diagnóstico de fallas. Un ANFIS puede ser visto como un sistema difuso, una red neuronal o una red neuronal difusa. En el método propuesto, primero se detecta la ocurrencia de la falla en un corto tiempo y se aísla la sección de la falla en la línea de transmisión. En el segundo paso se clasifica el tipo de la falla y se deduce cuál de las tres fases está expuesta a la falla. Finalmente, la localización de la falla se realiza fácilmente. Los datos de entrada del ANFIS son derivados de los valores fundamentales de las mediciones de la corriente y el voltaje (utilizando procesamiento digital de señales vía transformada de Fourier). Las pruebas fueron realizadas en una línea de transmisión, consistente de dos circuitos de 80 km de distancia, 66 kV de nivel de voltaje y 2 GVA de nivel de corto circuito. Para la detección y clasificación de fallas el ANFIS da las salidas correctas o esperadas, mientras que para la localización de la falla se tiene un error de 8%.

En [31], se presenta una combinación entre las técnicas de SVM y WT, para la identificación de zonas de fallas en una línea de transmisión de serie compensada. El método propuesto utiliza muestras de las tres corrientes en un ciclo de duración para llevar a cabo esta tarea. Inicialmente, las características de las corrientes de línea son extraídas en el primer nivel de descomposición de las muestras de corrientes utilizando DWT. Subsecuentemente, los rasgos característicos extraídos son aplicados como entradas en el SVM para determinar la zona de falla. La viabilidad del algoritmos es probado en una línea de transmisión de 300 km y 400 kV. Después de evaluar el algoritmo en alrededor de 25200 casos, la exactitud que se alcanza es de 93.167%, sin embargo, exclusivamente para fallas línea a línea se tiene un porcentaje menor o igual a 88.33%.

En esta investigación [32] se presenta un esquema para los relevadores de distancia utilizando ANFIS y Componentes de secuencia positiva de ondas de voltaje/corriente que pueden reducir el impacto de esas variables. El cambio de corriente es utilizada para la detección de fallas en las líneas de transmisión. Cuatro módulos ANFIS son utilizados como unidad de medición de la distancia. La parte real e imaginaria de las secuencias positivas de los voltajes y corrientes son seleccionados como las entradas de los ANFIS basados en numerosos experimentos. En el pre-procesamiento de las señales de entrada, los patrones de entrada para las ANFIS son generados por las muestras grabadas de las tres fases de las corrientes y voltajes de la localización del relevador. Estas muestras son procesadas por un filtro pasa-bajos de segundo orden y re-muestreado a una frecuencia de 1 kHz. Un segundo filtro digital FIR (respuesta de impulso finito) remueve la componente de corriente directa (DC), que realza las capacidades de entrenamiento de la ANFIS. La siguiente secuencia positiva del fasor de las señales de voltaje y corriente son obtenidas utilizando el algoritmo de la transformada discreta de Fourier de medio ciclo (HDFT) de las muestras del voltaje y la corriente. El método propuesto fue probado en una línea de transmisión simulada (con dos terminales/nodos), y adicionalmente también se estudio en una red de 6 nodos. Los resultados muestran una operación precisa mientras mantiene una buena exactitud cuando se presentan condiciones de falla diferentes, así también como cambios en la red. Otra ventaja aquí presentada, es el hecho de que una vez que la red esté entrenada para una distancia propuesta del relevador ésta puede ser aplicada a líneas con parámetros similares en un sistema diferente, sin necesidad del re-entrenamiento.

En [33], el método propuesto utiliza la transformada de Gabor (GT) como un extractor de rasgos característicos de las señales y las redes neuronales artificiales para el reconocimiento de patrones y la clasificación de procesos. El uso de la GT está motivada por el hecho de que las funciones elementales de Gabor tienen distintivamente una propiedad de optimización de localización en el dominio del tiempo y la frecuencia, la cual lleva a una extracción óptima de las características de las señales que son difíciles de ser detectadas utilizando otros detectores convencionales. La capacidad de generalización del sistema permite la detección de las señales de falla con bajas corrientes de falla y asociadas con cambios abruptos, decaimiento de la señal DC, armónicos no integrables y cantidades no estacionarias. Las pruebas del modelo propuesto fueron realizadas en una línea de transmisión de 100 km de longitud y 400 kV, mostrando resultados exitosos para fallas de alta y baja impedancia.

De acuerdo con el documento de He en [34], lo primero que se tiene que realizar para el diagnóstico de fallas en sistemas de red eléctrica, es construir la estructura de la RB con el campo del conocimiento experto. Lo segundo es obtener los parámetros de la RB por medio de un algoritmo de aprendizaje de propagación hacia atrás; y lo tercero es utilizar la RB para el diagnóstico de fallas e inferencia. Tomando la falla de L2 en Fig. 2 como ejemplo, el modelo del diagnóstico de falla en una línea parecida se da en la Fig. 3. Existen demasiados tipos de protección, por lo que será dividida en tres tipos de manera que se pueda establecer el modelo de diagnóstico como se realiza comúnmente: protección principal, la primera protección de respaldo y la segunda protección de respaldo. Para altos voltajes, para poder detectar la fuente de la falla, será necesaria la acción protectora y el 'break-off' en ambos lados de la línea con falla. En general, el centro de expedición deberá simultáneamente recibir las señales de acción de protección y sus correspondientes interruptores.

Aravena y Chowdhury en [35], establecen en su artículo, una nueva forma de detección de fallas de dos etapas, la primera consistente en crear indicadores que indiquen el estado normal y de fallas del sistema de potencia y la segunda parte consistente de una red neuronal para crear reglas de decisión. Este modelo no requiere de un modelo del sistema. Los indicadores son creados a partir del procesamiento de la señal y la teoría de las ondas. Los indicadores serán creados a partir del desarrollo de bancos de filtros, derivados de las ondas ortogonales Daubechies. La segunda parte se realiza mediante un detector de una neurona y una red auto-organizada Kohonen para la detección y clasificación de las fallas. Las simulaciones que se realizan para este método, sólo considera las fallas en corto circuito y no fallas simultáneas. Los resultados son exitosos, aunque pueden ser mejorados.

En el artículo realizado por Mori et al. [36], se propone un método eficiente para la detección de fallas con una MLP (red neuronal de múltiples capas de perceptrones) pre-acondicionada. Los objetivos de la detección de fallas son estimar la localización de la falla e identificar el tipo de falla. Se asume que las variables de entrada son corrientes de falla y las salidas son la localización y el tipo de falla. Dos técnicas de pre-acondicionamiento se utilizan en este artículo, para extraer las características especiales de los datos de entrada. Una de ellas es la Transformada de Fourier que transforma la onda de corriente en el dominio del tiempo a dominio en la frecuencia. Eso permite extraer carac-

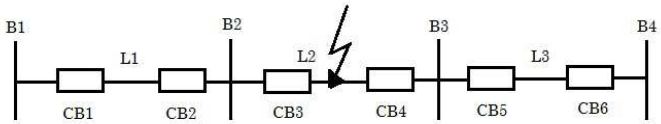

Figura 2: Muestra de línea

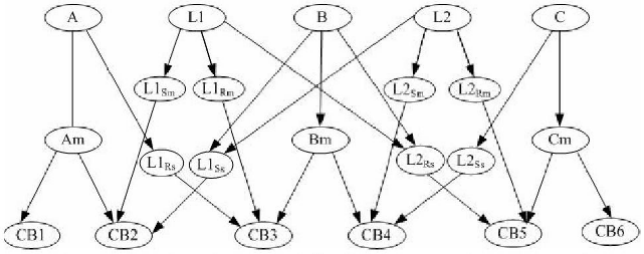

Figura 3: Modelo de falla de línea

terísticas de la corriente de falla con frecuencias. La otra es agrupar los datos de acuerdo a criterios de similitud. Mediante la clasificación de los datos en grupos y la construcción de una MLP para cada grupo, se puede lograr que todas las MLP's aprendan eficientemente, debido a que la similitud de los datos en cada grupo mejora el desempeño de la MLP. En específico, este artículo presenta un método híbrido de la transformada de Fourier, con agrupamiento DA (Recocido Determinístico) y MLP. El método propuesto, fue simulado y aplicado a un sistema de prueba. La simulación demuestra que este método tiene mejores resultados que los métodos convencionales (transformada de Fourier con MLP). Comparado con métodos convencionales, el método propuesto en [36] reduce el promedio de error en un 30% y el error máximo en 17.1% en términos de localización de falla y mejora el reconocimiento en un rango de 7.2% en términos del tipo de falla.

He et al. [37], crean un método nuevo para la detección de fallas en sistemas de potencia, combinando el método de la descomposición del valor singular (SVD), teoría de la entropía y la teoría de la transformada de las ondas. El nombre de esta nueva creación es denominado Método de Ondas de Entropía Singular. Este método se crea debido a que un método muy utilizado para analizar las formas de onda transitorias en los sistemas de potencia para observar las firmas únicas que revelan si hay falla o no, es la transformada de las ondas. Este método tiene aún algunos problemas severos para las aplicaciones de detección automática de fallas, debido a que la transformada de ondas está limitada a un número de imágenes de la transformada, y sus resultados tienen la misma cantidad de datos, el método de extracción de características cuantitativas se realiza rara vez, lo que obstaculiza su aplicación en áreas de sistemas de potencia como protección, detección de fallas, entre otras. Si el método de transformada de ondas se combina con el método SVD y la teoría de entropía, estas desventajas pueden superarse. El experimento de simulación muestra que el método de ondas de entropía singular es sensible a las señales abruptas, especialmente para las repentinas señales transitorias que aparecen, y es insensible al ruido.

En el artículo [38] realizado por Douglas, la transformada discreta de ondas es aplicada a un sistema de potencia integrada en un barco para la detección de fallas en un sistema sin

conexión a tierra. Esto se realiza debido a que el sistema de potencia integrado (IPS) en los barcos de la marina está basado en un sistema sin conexión a tierra; los capacitores naturales del cable y los filtros EMI (interferencia electromagnética) proveen caminos con conexión a tierra para los cascos del barco. Por lo que existe una "Tierra Virtual" entre los módulos del IPS. Sin embargo la corriente de falla es muy pequeña para que una sola línea de falla a tierra sea detectada en este sistema sin conexión a tierra, lo que permite la operación continua pero también hace difícil la detección de fallas. Este artículo demuestra que el análisis de ondas puede ser utilizado para detectar las fallas de línea a tierra.

Samantaray et. al [39], presentan en su artículo un método para el detección de fallas para redes de sistema de potencia utilizando el análisis tiempo-frecuencia. La transformada S con ventana compleja es utilizada para generar contornos de frecuencia (contornos S), que distingue entre una condición de falla de una sin falla. Los datos de corriente de un ciclo atrás y un ciclo a partir del inicio de falla son procesados a través de la transformada S para generar patrones de tiempo-frecuencia con ventanas variantes. Los patrones generados de tiempo-frecuencia claramente distinguen la condición de falla de la no falla, debido a que los contornos son concéntricos a altas escalas de frecuencia para la condición de falla pero en caso de una fase sin falla el contorno S es concéntrico en escalas de frecuencia baja. La transformada S es muy insensible al ruido, por lo que el método es muy exacto y robusto para la protección de las líneas de transmisión.

Rodríguez-Cortés et. al [40], en su artículo proponen un esquema de monitoreo en línea para detectar pérdidas en las líneas y cambios en las cargas del bus de un sistema de potencia. El esquema de monitoreo propuesto no depende en los esquemas de estimación clásica utilizado en los sistemas de potencia; sino que monitorea, un cuidadoso y selecto estado de señales dependientes, utilizando un observador en línea. La solución basada en el modelo propuesto en este artículo, muestra la viabilidad de generar un residuo para la detección de fallas, sin embargo, esto se logra solo en el caso ideal, en donde todos los estados y parámetros son conocidos. La simulación numérica muestra la capacidad de distinguir entre los dos eventos (falla o no falla) se ve degradado por el desempeño del observador, por lo que los autores proponen el diseño de un observador adaptable para el mejor funcionamiento de este método.

En el documento [41] de Xu y Chow, se presenta una aplicación de métodos de regresión combinados con redes neuronales para clasificar las causas de una falla en una red eléctrica. En [42] y [43] se proponen procedimientos para identificar fallas utilizando redes de Petri.

Por último, cabe mencionar que aunque las Redes Bayesianas Híbridas ya han sido utilizadas en el diagnóstico de sistemas dinámicos (como el trabajo de Lerner en [44]), no se han utilizado en sistemas complejos con gran interconexión y un elevado número de componentes, como lo es una red eléctrica, por lo que uno de los objetivos principales de esta tesis es la aportación en este dominio.

Como conclusión, se puede observar que ninguno de los trabajos aquí mencionados aborda de manera simultánea los problemas de: múltiples fallas, ruido en la información, falta de información y procesamiento simultáneo de datos discretos y continuos.

Autor	*Método*	*Modelo estudiado*	*Fallas detectadas*
Jafarian et al. [19]	WT con PCA	Línea de transmisión de 400 kV.	Línea a línea, una, dos y tres fases a tierra.
Shiroei et al. [20]	PMU	Red de 6 nodos.	Línea a línea, una, dos y tres fases a tierra.
Edachali et al. [21]	Sensores FBG con PLC/SCADA	3 sensores instalados en cada fase de una línea de transmisión.	Fallas causadas por conductores rotos en la línea de transmisión.
Tian et al.[22]	WT	Sistema de transmisión de potencia de una mina de carbón.	Una fase a tierra.
Bo et al. [23]	Técnicas de protección posicional combinada (relevador central)	Sistema de transmisión de potencia basado en una línea vertical de 400 kV.	Una fase a tierra.
Ravindranath et al. [24]	WT	Línea de transmisión de 500 kV.	Línea a línea, una, dos y tres fases a tierra.
Hua Lan et al. [25]	EMD y LS-SVM con BCC	Línea de transmisión con dos terminales (generadores).	Una fase a tierra y distingue entre fallas transitorias y permanentes.
Istrate et al. [26]	Modelos ATP con filtros DFT	Línea de transmisión de 300 km con dos máquinas de 400 kV.	Cortos circuito de una sola fase.
Youssef et al. [27]	SVM	Línea de transmisión en sistema de potencia trifásico.	Línea a línea, una y dos fases a tierra.
Geethanjali et al. [28]	DWT con ANN	Línea de transmisión de 110 kV, 50 Hz y 200 km de longitud.	Línea a línea, una y dos fases a tierra, tres fases en corto circuito, y operación de interruptor de seguridad.
Valsan et al. [29]	Teoría e implementación FPGA	Línea de transmisión de 400 kV con 4 nodos.	Línea a línea, una, dos y tres fases a tierra.
Kamel et al. [30]	ANFIS	Línea de transmisión de 66 kV y 80 km.	Línea a línea, una, dos y tres fases a tierra.
Parikh et al. [31]	SVM con WT	Línea de transmisión de 400 kV y 300 km.	Línea a línea, una, dos y tres fases a tierra.
Zuyi et al. [32]	ANFIS con filtros FIR	Línea de transmisión y red de 6 nodos.	Línea a línea, una, dos y tres fases a tierra.
Kawady et al. [33]	GT con ANN	Línea de transmisión de 100 km y 400 kV.	Una fase a tierra, alta impedancia.
He [34]	RB	Línea de transmisión con 6 cargas.	Falla en línea de transmisión (ruptura).
Aravena et al. [35]	ANN con WT	Línea de transmisión.	Corto circuito.
Mori et al. [36]	ANN con FFT y DA	Línea de transmisión.	Una, dos y tres fases a tierra, corto circuito en dos y tres fases.
Zhengyou et al. [37]	WSE	Sistema de potencia.	Lecturas inmunes a ruido.
Douglas et al. [38]	WT	Sistema de protección de potencia en barcos.	Fallas de línea a tierra.
Samantary et al. [39]	Transformada S, análisis tiempo-frecuencia	Línea de transmisión 300 km y 400 kV.	Una, dos y tres fases a tierra, corto circuito en dos y tres fases.
Rdz-Cortés et al. [40]	Modelo analítico	Circuito con generador.	Pérdidas en las líneas y cambios en las cargas del bus.
Xu et al. [41]	ANN y logística de regresión	Red eléctrica.	Fallas mayores en la red de distribución.
Jin et al. [42] y Ren et al. [43]	Redes Petri	Sistemas de Potencia (28 elementos del sistema)	7 tipos de fallas, que incluyen fallas en los interruptores de seguridad, mediciones, etcétera.
Lerner et al. [44]	RBH	Sistemas de 5 tanques de agua	Explosión de una tubería, incremento o decremento de la resistencia de la tubería.

Tabla 2: Resumen del estado del arte de sección 1.2.2

Los anteriores artículos muestran los diversos esfuerzos que se han realizado para la correcta detección de fallas en los sistemas de potencia. Es importante mencionar, que lo que la mayoría de los investigadores están intentando realizar, es primero la creación de indicadores de falla o residuales de falla, que posteriormente se utilizan en algún clasificador de falla; es decir, un modelo de 2 etapas, igual al que se propondrá en este trabajo.

Se puede mencionar también que entre los diversos métodos para la realización de indicadores de falla en los sistemas de potencia se encuentran: la teoría de las ondas, la transformada S, la elaboración del modelo mecánico del sistema, creación de residuos, transformada de Fourier, entre otros. En este proyecto se verá, que el acondicionamiento o la creación de indicadores de falla se realizarán de una manera más sencilla, en sus primeros intentos; debido a que nuestro interés no radica en realizar diversas pruebas con frecuencias diferentes debido a la gran cantidad de datos que se tienen, y por lo tanto, tampoco se puede crear un modelo analítico para la red elegida. En los últimos modelos que se presentarán, se realizarán índices de fallas mediante análisis de frecuencia en los datos, pero no en toda la gama de frecuencias, sino solamente en la frecuencia más alta contenida. En posteriores secciones, se explicará el procedimiento realizado.

Entre los clasificadores de falla más utilizados, como ya se mencionó anteriormente, se encuentran los sistemas expertos, en particular las redes neuronales. Este proyecto intentará probar un sistema experto diferente (Redes Bayesianas Híbridas), y realizar comparaciones con proyectos que hayan utilizado otros esquemas, como por ejemplo las ANN's.

1.3 La propuesta

1.3.1 El objetivo

El objetivo general de este trabajo es generar una nuevo modelo gráfico probabilístico híbrido de una red de distribución eléctrica, utilizando Redes Bayesianas Híbridas, que permita realizar la detección y diagnóstico de fallas simples y múltiples, simétricas y asimétricas, en ambientes de ruido y de pérdida de información.

Los objetivos particulares a cumplir en este trabajo de investigación son los siguientes:

1. Generación de datos en escenarios de fallas simples y múltiples, simétricas y asimétricas, en el software MICROTRAN.

2. Modelación e inferencia de la red eléctrica con Redes Bayesianas Híbridas, utilizando el software HUGIN.

3. Validación de resultados generados por el modelo obtenido con Redes Bayesianas Híbridas.

1.3.2 Estrategias conceptuales

Diversos métodos se han utilizado para la detección de fallas en redes eléctricas, entre los cuáles se pueden nombrar: sistemas expertos, redes neuronales y diagnóstico de fallas basado en teorías óptimas [3]. Sin embargo, dentro de los sistemas expertos, las Redes Bayesianas (modelos probabilísticos consistentes de variables y relaciones causa-efecto entre ellas [45]) es el único método que puede manejar grandes cantidades de datos e incertidumbre creados por factores tales como operación no deseada y fallas de protección para operar, errores de inferencia en el canal de transmisión y el tiempo necesario para la acción de protección [34]. Es por esto, que las Redes Bayesianas es el método elegido para la detección y diagnóstico de fallas para el caso particular aquí propuesto, ya que ésta puede manejar datos continuos y discretos, los cuales se presentan en un sistema de red eléctrica.

1.3.3 Definición de estrategia

Las redes eléctricas localizadas en las industrias, tienen una complejidad alta debido al número de dispositivos presentes en la red, al alto grado de interconexión y al exceso de información, consecuencia del crecimiento acelerado de la demanda. Garza et al. [2], explican la necesidad de tecnología y supervisión de sistemas más sofisticados, que dificultan las labores de los operadores. Es por esto que se desea realizar una nueva estructura para la detección o diagnóstico de fallas en una red eléctrica, o en otras palabras averiguar cuál es el estado de los nodos que componen a la red, y presentárselo de una manera amigable al trabajador. Los nodos de la red, pueden presentar sólo dos estados: 'normal' o 'falla', y el estado de falla se subdivide en otras 4 secciones, que definen el tipo de la falla que se presenta en el sistema. Sin embargo, para poder llegar a este resultado final se tienen que realizar una serie de pasos, mejor mostrados en el diagrama de la Fig. 4 (basado en [46]).

El esquema general de detección de fallas mostrado en la Fig. 4, nos muestra los pasos necesarios para que la información obtenida de un proceso sea tratada y posteriormente mostrada al operador. El primer paso consiste en la adquisición de datos a partir del proceso que se desea analizar; en el segundo paso, estos serán sometidos a un “monitoreo inteligente” en donde las variables más importantes serán acondicionadas, para su uso posterior en el tercer paso, el cual consiste del modelo probabilístico híbrido para el diagnóstico de fallas. Una vez realizado lo anterior, simplemente se mostrarán los

resultados al operador en una interfaz creada con dicho propósito. Este esquema se realizará de manera cíclica para la mejor identificación de las fallas.

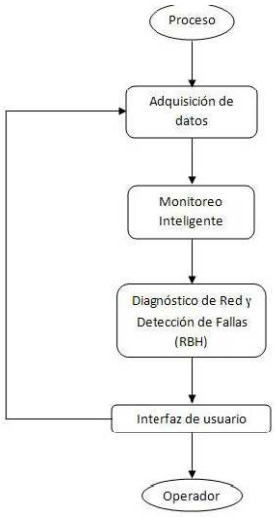

Figura 4: Esquema general detección de fallas

La cantidad de información que se puede obtener de la red eléctrica, como consecuencia del gran número de componentes que se tienen, representa un problema de gran importancia para todo sistema que desea un rápido y acertado procesamiento de datos; es por esto, que se necesita un software capaz de obtener y almacenar estos datos de una manera rápida y eficiente. El software MicroTran [47], es la herramienta elegida para esta tarea, debido a que a través de él se podrán generar los diferentes escenarios de falla y almacenar los datos que resulten de estos para su posterior uso en el diagnóstico y detección de fallas.

Otro factor importante en el análisis de datos son las implicaciones que tiene la aparición recurrente de incertidumbre en nuestra información. En diversos artículos se plantean métodos distintos para lidiar con esta incertidumbre, siendo la técnica de inteligencia artificial uno de los más populares. Por ejemplo en Zhao et al. [3] realizan un sistema para diagnóstico de fallas basado en lógica difusa, en el cuál el sistema experto se basa en el razonamiento lógico y utiliza valores de voltajes y corrientes para éste, mientras que para el avance del diagnóstico de fallas combina la información con datos obtenidos de protección y candados de seguridad. Aunque este sistema resolvió partes del problema, está incompleto en el sentido en que no presenta buenos resultados cuando se hace a gran escala. Por estas razones, el modelo gráfico probabilístico denominado Red Bayesiana, es el modelo acorde para la solución de este problema, ya que puede trabajar con grandes cantidades de datos y manejar bien la incertidumbre.

Según Venkatasubramanian et al. [46], un punto importante que se debe enfatizar sobre los métodos de detección de fallas, es que la mayoría de las veces un solo método no es suficiente para cumplir con los requisitos del diagnóstico de fallas de determinado proceso. Es por eso que algunos métodos se complementan con otros dando mejores resultados. Integrar estas características complementarias es una forma de desarrollar métodos

híbridos que pueden superar ciertas limitaciones que tendrían por sí solos. Las Redes Bayesianas generalmente se trabajan como modelos probabilísticos en donde sólo pueden entrar datos discretos para el cálculo del diagnóstico, sin embargo, una rama que sale de estas redes son las Redes Bayesianas Híbridas, en donde pueden combinarse datos discretos y datos análogos para la detección de fallas. Estas últimas serán las utilizadas para la propuesta aquí dada, debido a que en una red eléctrica los voltajes y corrientes (evidencia) son análogos, basados en distribuciones de Gauss. Este tipo de Redes, ya ha sido antes investigada por otros autores, como He en [34], sin embargo es una rama de la detección de fallas que aún no ha sido completamente desarrollada. Las Redes Bayesianas Híbridas, serán realizadas mediante el software HUGIN EXPERT 7.0 [48].

Una vez resueltos los problemas particulares, el sistema de detección de fallas trabajará correctamente, de manera que se podrá dar un diagnóstico en línea del estado en el que se encuentra una red eléctrica industrial. Una falla detectada rápidamente significará una mejor eficiencia y calidad del producto en determinada empresa, así como también un mayor nivel de seguridad tanto para los trabajadores como para la maquinaria.

Por último cabe mencionar, que esta estructura para detección de fallas podría ser usada en redes eléctricas de diferentes industrias, así como en todo campo en donde se requiere el análisis de información con una cantidad de datos extensa, incertidumbre y combinación de parámetros discretos y continuos. En un futuro también se podrá utilizar para realizar controladores en línea, así también como ayuda en la toma de decisiones.

1.3.4 Red Eléctrica Industrial de Aplicación

La red eléctrica industrial que será utilizada para el estudio, puede ser vista en la Fig. 1. Esta red fue previamente utilizada por diversos investigadores en [2], para realizar modelación gráfica probabilística discreta con modelos probabilísticos de máxima entropía para el diagnóstico de fallas. La red consiste de los siguientes elementos (para mayor información, ver Apéndice A):

- 24 nodos principales
- 20 generadores con diferentes voltajes, con valores en un rango de 124 a 230 kV
- 21 cargas estáticas y 15 cargas dinámicas, constituidas cada una por una resistencia y una inductancia de diferentes valores
- 68 interruptores de protección

El análisis de la información y la detección de fallas se realizará en los 24 nodos principales. Las cargas dinámicas son cargas que serán conectadas dependiendo del tiempo

de apertura y cierre de interruptores, mientras que las cargas estáticas estarán siempre conectadas. Las fallas pueden presentarse en cualquier nodo y pueden ser de 4 tipos (ver Fig. 5):

- Línea a línea
- 1 fase a Tierra
- 2 fases a Tierra
- 3 fases a Tierra

Los breakers, o dispositivos de seguridad intrínsecos en la red, pueden presentar tres estados, necesarios para el correcto funcionamiento del diagnóstico de fallas; éstos son:

- OK: Este estado notifica que el nodo al que se encuentra conectado el breaker, se encuentra en correcto funcionamiento
- FAIL: Este estado notifica al operador que no pudo operar debido a una falla interna.
- OPEN: Este estado notifica al usuario, que el breaker tuvo que abrirse para proteger al nodo que se encuentra próximo, debido a que el mismo u otros nodos fallaron.

1.4 Contribuciones de la Tesis

Las contribuciones principales que brindará este trabajo, son las siguientes:

- Una nueva estructura de detección y diagnóstico de fallas múltiples de redes eléctricas basada en un modelo gráfico probabilísticos híbrido.
- La apertura de una línea de investigación en detección de fallas en procesos complejos con modelos probabilísticos híbridos, que pueden ser aplicables a sistemas industriales en general; ésto debido a que la estructura del modelo es flexible, por lo que puede ser modificada y adaptada a diversos procesos basada en el análisis de un historial de datos confiables.

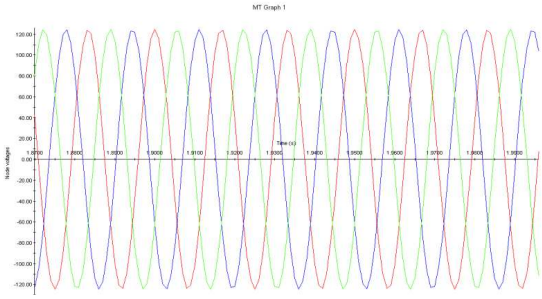

(a)

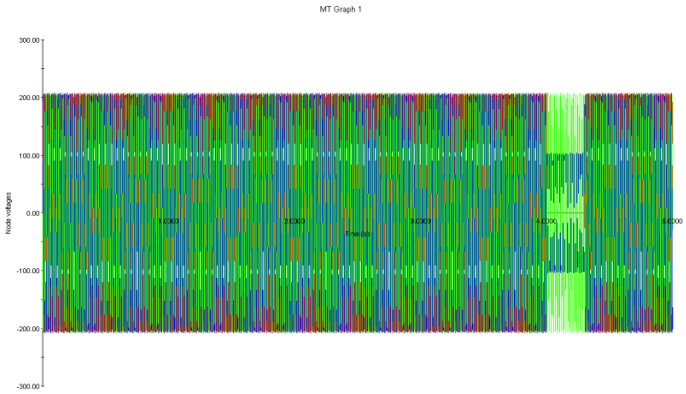

(b)

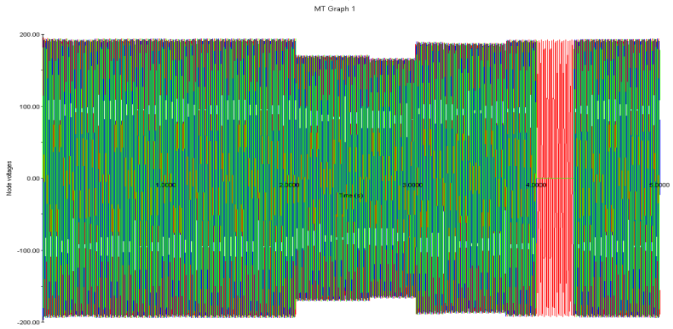

(c)

Figura 5: (a) Funcionamiento normal de las 3 fases de un nodo de la red eléctrica, (b) Falla tipo línea a línea (fase A y B), (c) Falla de tipo 1 fase a tierra (A-Gnd)

1.5 Organización de la Tesis

Este texto presenta la propuesta a Tesis en el área de detección de fallas mediante Redes Bayesianas Híbridas. El documento se divide en tres partes, en donde en la primera parte, se presenta un método sencillo de extracción de datos para los nodos de la red eléctrica, los experimentos realizados y sus resultados; en la segunda parte se presenta la optimización de estos resultados y en la tercera parte se propone otro método de extracción de datos un poco más complicado. La primera parte se compone del capítulo 2, 3 y 4, la segunda parte

está integrada por el capítulo 5 y la tercera parte comprende el capítulo 6 y 7. Por último, en el capítulo 8 se darán las conclusiones sobre todo lo anteriormente realizado, así mismo como los puntos fuertes y limitaciones del modelo que aquí se presenta y un breve resumen del trabajo a futuro que se quiere desarrollar en este campo.

En el siguiente capítulo, el cuál es el primero de la primera parte de la tesis, se presenta de una manera más profunda la metodología propuesta, incluyendo todo el material necesario para el entendimiento de la misma. En el capítulo 3, se presentará la parte experimental de la propuesta, explicando claramente que fue hecho en cada uno de los modelos presentados. Los resultados de estos experimentos serán enunciados en el capítulo 4.

En el capítulo 5, se presenta la teoría de la técnica de optimización utilizada en el último modelo presentado en el capítulo 3 y la mejora que se obtuvo.

En el capítulo 6 y 7, los cuales representan la tercera parte de la tesis, se presenta la nueva metodología propuesta para la extracción de datos, incluyendo el material necesario para el entendimiento de la misma. También se presentan los nuevos modelos generados y sus resultados en comparación con los ya obtenidos anteriormente.

CAPÍTULO 2: PRIMERA PARTE
Metodología propuesta

2.1 Marco Teórico

A continuación se presentará brevemente la descripción de los diversos tipos de detección de fallas, con el fin de dar un panorama general sobre este tema y mostrar la gran cantidad de modelos que existen. También se presentará el fundamento teórico de las Redes Bayesianas, seguidas por las Redes Bayesianas Híbridas. Enseguida se mencionarán brevemente paquetes de software que se van a utilizar.

2.1.1 Detección y diagnóstico de fallas

Según el Dr. Vekatasubramanian et al. en [46], en los últimos años han surgido una cantidad considerable de métodos de detección y diagnóstico de fallas, las cuáles se clasifican en 3 grandes grupos:

1. Cuantitativos basados en modelos
2. Cualitativos basados en modelos
3. Basados en historial de datos del proceso

Los métodos cuantitativos son aquellos que confían en las relaciones matemáticas que existen entre las variables y un modelo consistente trata de expresar estas relaciones en una forma cerrada. En general estos métodos hacen uso de la siguiente estructura:

$$\frac{dx}{dt} = Ax + Bu + Ed + Ff \tag{1}$$

$$y = Cx + Du \tag{2}$$

donde los estados son *"x"*, las entradas *"u"*, las salidas *"y"*, las perturbaciones *"d"* y las fallas *"f"*.

De una forma más sencilla, la detección de fallas se basa en obtener las discrepancias entre el comportamiento observado y la predicción del modelo. Algunas técnicas utilizadas son: la estimación de estados, la identificación paramétrica y las relaciones de paridad.

En los métodos cualitativos basados en modelos, la estrategia utilizada es el razonamiento causa-efecto del comportamiento del sistema. Entre los métodos más destacados se encuentran: el diagrama de árbol y los diagramas de señales. Una limitación de estos métodos es la generación de grandes números de hipótesis, lo que equivale a una baja resolución en el proceso de toma de decisiones con más incertidumbre. Una ventaja es que poseen la distinción de encontrar todos los posibles candidatos de falla.

Por último los métodos basados en historial de datos del proceso, realizan la transformación de esos datos para extraer las características relevantes que ayuden a discriminar entre el estado de operación normal y los modos de falla del sistema. Estas transformaciones pueden ser cualitativas, como las utilizadas por los sistemas expertos, o cuantitativas como las utilizadas por las redes neuronales o análisis de componentes principales. En ésta última clasificación se ubica el modelo que se desea utilizar en esta propuesta, denominado Redes Bayesianas Híbridas.

2.1.2 Redes Bayesianas

De acuerdo con Riascos et. al en [49], una red bayesiana es una estructura que modela gráficamente las relaciones de dependencia probabilística dentro de un grupo de variables. La estructura de la Red y las probabilidades condicionales componen una Red Bayesiana.

Según Zhao en [11], la Red Bayesiana es una gráfica directa en la cual se tiene que:

1. Un conjunto de variables aleatorias conforma los nodos de la red.

2. Un conjunto de líneas directas o flechas conecta los pares de nodos.

3. Cada nodo tiene una tabla de probabilidad condicional (TPC) que cuantifica el efecto que tienen los padres sobre un nodo. Los padres de los nodos son todos aquellos nodos que tienen flechas señalando directamente a éste.

4. La gráfica no tiene ciclos directos (por lo tanto es una gráfica acíclica directa o DAG).

De acuerdo con Jensen [50], las Redes Bayesianas son redes causales que consisten de un conjunto de variables y de líneas dirigidas entre las variables, dando lugar a una estructura denominada matemáticamente como una gráfica directa. Las relaciones de las variables que se dan dentro de estas gráficas, se denominan relaciones familiares, es decir, si hay vínculo directo de la variable A a la B, se dice que la variable A es padre de la variable B o que la variable B es hija de la variable A.

Las variables representan eventos (proposiciones). Estas pueden ser continuas o con un número contable de estados (discretas), sin embargo en esta sección se considerarán solamente las variables que posean un número finito de estados.

Una Red Bayesiana provee una descripción completa de un dominio. Cada entrada en una unión de la distribución probabilística puede ser calculada por la información en la Red. Una entrada genérica en una unión es la probabilidad de una conjunción de tareas particulares para cada variable. El valor de esta entrada, es dada por la siguiente fórmula:

$$p(X_1,\ldots,X_n) = \prod_{i=1}^{n} p(X_i | Parents(X_i)) \tag{3}$$

De acuerdo con Riascos et. al en [49], la construcción de una gráfica que describa el diagnóstico del proceso puede ser conducida de dos maneras:

- Basada en el conocimiento humano del proceso, donde las relaciones entre las variables son establecidas para definir el criterio para elegir el siguiente estado (i.e. la relación entre las variables y sus padres); o

- Basadas en métodos probabilísticos usando bases de datos almacenadas.

Según [50], el concepto básico del tratamiento bayesiano de certezas en las redes causales es la probabilidad condicional; la cual, establece lo siguiente: *"Dado el evento b (y todo lo demás conocido es irrelevante para a), entonces la probabilidad del evento a es x"*.

La notación para el enunciado dado arriba, basado en la ecuación 3, queda de la siguiente manera:

$$P(a|b) = x \tag{4}$$

La regla fundamental del cálculo de probabilidad está dado por:

$$P(a|b)P(b) = P(a,b), \tag{5}$$

donde *P(a,b)* es la probabilidad del evento conjunto $a \wedge b$.

De la ecuación 5 sigue $P(a|b)P(b) = P(b|a)P(a)$ y esto nos lleva al bien conocido *Teorema de Bayes*:

$$P(b|a) = \frac{P(a|b)P(b)}{P(a)} \tag{6}$$

De una tabla *P(A,B)* de probabilidades $P(a_i, b_j)$ la distribución de probabilidad *P(A)* puede ser calculada. Sea a_i un estado de *A*. Hay exactamente *m* eventos diferentes para la cual *A* esté en el estado a_i, nombrados eventos mutuamente exclusivos $(a_i, b_1),\ldots,(a_i, b_m)$. Por lo que tenemos,

$$P(a_i) = \sum_{j=1}^{m} P(a_i, b_j) \tag{7}$$

Este cálculo es denominado *marginalización* y se dice que la variable B es marginalizada por $P(A,B)$ (resultando en $P(A)$). La notación es la siguiente:

$$P(A) = \sum_{B} P(A, B) \tag{8}$$

Sea U el universo de una Red Bayesiana. La evidencia es la información del estado de las variables U. Por simplicidad se va a considerar evidencia del tipo *"La variable X está en el estado x"*. Se denotará como "*e*" al conjunto de dichos enunciados.

La inferencia Bayesiana es un tipo de inferencia estadística en la que las evidencias u observaciones se emplean para actualizar o inferir la probabilidad de que una hipótesis pueda ser cierta. El nombre *"bayesiana"* proviene de uso frecuente que se hace del Teorema de Bayes durante el proceso de inferencia.

La tarea básica de un sistema de inferencia probabilística es calcular las distribuciones de probabilidad posteriores para un conjunto de variables dado un evento observado, es decir, dada una asignación de valores a un conjunto de variables de evidencia.

Para realizar lo anterior, se calcula $P(X,e)$ para toda X, y luego $P(X|e)$ es calculada mediante la normalización de $P(X,e)$:

$$P(X|e) = \frac{P(X,e)}{P(e)} \tag{9}$$

donde $P(e) = \sum_x P(X, e)$.

2.1.3 Redes Bayesianas Híbridas

Las Redes Bayesianas Híbridas difieren de las Redes Bayesianas normales, en que éstas pueden manejar datos continuos así como también datos discretos. Las variables continuas deben tener una distribución condicional Gaussiana (también conocida como distribución normal) en los valores de sus padres. Según los documentos de apoyo del software HUGIN en [48], la distribución para una variable continua Y con padres discretos I y padres continuos Z es una distribución Gaussiana condicional (en una dimensión) con los valores de los padres:

$$P(Y|I = i, Z = z) = N(\alpha(i) + \beta(i)^{\tau} z, \gamma(i)) \tag{10}$$

De esta ecuación se debe notar que la media depende linealmente de las variables padres continuas y que la varianza no depende de las variables de padres continuos. Por otra parte, los valores de la función lineal y la varianza tienen permitido depender de las variables padres discretas. Estas restricciones nos aseguran que las inferencias puedan ser realizadas. También se debe de tomar en cuenta que las variables discretas no pueden tener padres continuos.

Para entender más a fondo el funcionamiento de las Redes Híbridas y la ecuación 10 que será utilizada, tenemos que basarnos en los métodos de propagación de probabilidades, medias y varianzas en sistemas que tengan distribuciones gaussianas. Por lo que a continuación se da un breve resumen de la notación estándar refiriéndonos a Lauritzen y Wermuth [51].

El conjunto de variables V esta dividido como $V = \Delta \cup \Gamma$ en variables discretas (Δ) y continuas (Γ). Un elemento típico del espacio de estados conjunto es denotado como en una de las siguientes posibilidades:

$$x = (x_\alpha)_{\alpha \in V} = (i, y) = ((i_\delta)_{\delta \in \Delta}, (y_\gamma)_{\gamma \in \Gamma})), \tag{11}$$

donde i_δ son cualitativas y y_γ son valores reales. La combinación particular $i = (i_\delta)_{\delta \in \Delta}$ es referida como una *célula*, y el conjunto de células esta denotado por $\Im$. La distribución conjunta de las variables, se supone tiene una densidad f con

$$f(x) = f(i, y) = x(i) \exp\left\{\boldsymbol{g}(i) + \boldsymbol{h}(i)'y - \frac{y'\boldsymbol{K}(i)y}{2}\right\}, \tag{12}$$

donde $X(i) \in \{0,1\}$ indica si f es positiva en **i** y **A'** es la transpuesta de la matriz **A**. Entonces se puede decir que X sigue una distribución CG (Gaussiana Continua), que es equivalente al enunciado:

$$£(X_\Gamma | X_\Delta = i) = N_{|\Gamma|}(\xi(i), \Sigma(i)), \tag{13}$$

cuando $p(i) = P\{X_\Delta = i\} > 0$,
donde $X_A = (X_\alpha)_{\alpha \in A}$ y así sucesivamente, y

$$\xi(i) = \boldsymbol{K}(i)^{-1}\boldsymbol{h}(i), \quad \sum i = \boldsymbol{K}(i)^{-1}, \tag{14}$$

la última siendo positiva definida. La tripleta (**g, h, K**) –definida solo por *x(i)>0*– constituye las características canónicas de la distribución, y $\{p, \xi, \Sigma\}$ son las características del momento.

Una parte básica de la tarea computacional consiste en la actualización de la distribución conjunta a la luz de la evidencia, correspondiente al proceso condicionado. Una manera simple de hacer esto, es mediante el cómputo con funciones de densidad no normalizadas.

Es por esto, que la notación de una distribución CG se extiende a un potencial CG, la cuál es cualquier función ϕ de la forma

$$\phi(x) = \phi(i, y) = X(i) \exp\left\{g(i) + \boldsymbol{h}(i)'y - \frac{y'\boldsymbol{K}(i)y}{2}\right\}, \tag{15}$$

donde se asume que $\boldsymbol{K}(i)$ es una matriz simétrica. Por lo que ϕ, no es necesariamente una densidad.

Una diferencia básica es que las características del momento para un potencial CG son solamente definidas cuando $\boldsymbol{K}$ es positiva definida para todas las i con $x(i)>0$. Entonces Σ y ξ son dadas como en (14), donde

$$p(i) \propto \{det \sum(i)\}^{1/2} \exp\{\boldsymbol{g}(i) + \boldsymbol{h}(i)'\sum(i)\boldsymbol{h}(i)/2\}, \tag{16}$$

donde significa *"proporcional a"*. Si las características del momento $\{p, \xi, \Sigma\}$ son dadas, entonces se pueden calcular las características canónicas como $\boldsymbol{K}(i) = \sum(i)^{-1}, \boldsymbol{h}(i) = \boldsymbol{K}(i)\xi(i),$ y $g(i) = log\, p(i) + \{log\, det\, \boldsymbol{K}(i) - |\Gamma| log\, (2\pi) - \xi(i)'\boldsymbol{K}(i)\xi(i)\}/2.$

Una vez explicado, todo el trasfondo de la probabilidad con distribuciones gaussianas, podemos regresar al modelo que se utilizará para manejar este tipo de distribuciones.

En el caso de que la variable A sea continua, se asume la distribución condicional de la repuesta de la variable Y asociada con A del siguiente tipo,

$$£(Y|pa(A)) = N(\alpha(i) + \beta(i)'z, \gamma(i)). \tag{17}$$

Como se puede observar la ecuación 17, no es otra que la ecuación 10, un poco modificada, pero con la intención de que las literales sean iguales a las utilizadas en la explicación anterior. Aquí $pa(A)$ es una notación corta para la combinación de estados discretos y continuos **(i, z)** de las variables que son padres de A. En esta fórmula $\gamma(i) > 0, \alpha(i)$ es un número real, y $\beta(i)$ es una vector de la misma dimensión que la parte continua **z** de las variables padres.

La densidad condicional que corresponde a un potencial CG ϕ_A con definición en la combinación (**i**, **z**, y) de las variables padres (**i**, **z**) y la variable respuesta y con características canónicas ($\mathbf{g_A}$, $\mathbf{h_A}$, $\mathbf{K_A}$), donde

$$g_A(i) = -\frac{\alpha(i)^2}{2\gamma(i)} - [\log\{2\pi\gamma(i)\}]/2, \tag{18}$$

$$\boldsymbol{h}_A(i) = \frac{\alpha(i)}{\gamma(i)}\begin{pmatrix} 1 \\ -\beta(i) \end{pmatrix}, \tag{19}$$

Y

$$\boldsymbol{K}_A(i) = \frac{1}{\gamma(i)}\begin{pmatrix} 1 & -\beta(i) \\ -\beta(i) & \beta(i)\beta(i)' \end{pmatrix} \tag{20}$$

Esto viene de los cálculos directos usados en la expresión para la densidad normal. Se escribe simplemente $\phi(i,z,y) = \{2\pi\gamma(i)\}^{-1/2} \exp\left[-\{y-\alpha(i)-\beta(i)'z\}^2 / \{2\gamma(i)\}\right]$, se resuelven los paréntesis, se toman los logaritmos, y se identifican los términos. Cabe mencionar que $\mathbf{K_A}$(i) tiene un rango de uno y es, por lo tanto, típicamente no positiva definida.

2.1.4 Métodos de detección de fallas en Sistemas de Potencia

En [52] se señala que los estudios convencionales en detección de fallas pueden ser clasificados en los siguientes 3 métodos:

1. Método basado en la teoría del circuito
2. Método basado en la teoría de propagación
3. Sistemas Inteligentes

El primer método detecta la falla a través de los voltajes de nodos, corrientes en las líneas de transmisión y cambios en la impedancia. En esta división existen diversos métodos que se han utilizado a través de los años. Primero se menciona el método del pulso de radar, en donde se mide el tiempo que tarda en regresar un pulso a partir de su emisión y depende de la medición de la impedancia en el punto de falla. Westlin y Bubenko [53], en 1976, diseñaron un algoritmo utilizando el método de Newton-Raphson para solucionar una ecuación no lineal, sin embargo se necesita actualizar en todo momento los cambios en la topología. Richard y Tan [54], en 1986, compararon voltajes y corrientes en las líneas de transmisión para localizar fallas, sin embargo, esto requería de mucha exactitud en el modelo y de cálculos iterativos. En 1995, Kezunovic [55], utilizó un muestreo sincronizado para la detección de fallas, donde la información de un grabador de fallas era sincronizado en las orillas de las líneas de transmisión utilizando FPS que fue utilizado para detectar, clasificar y localizar la falla. En 2001, Chen [56], utilizó un algoritmo de localización de fallas el cual se basaba en la técnica de parámetros distribuidos utilizando muestras sincronizadas con un GPS. Las simulaciones en computadora muestran una gran exactitud y localización del error cerca del 0.4%. En el mismo año, pero gracias a Sauhats [57], [58], [59], se utilizó información estadística acerca de las impedancias equivalentes del sistema del final de las líneas de transmisión no monitoreadas para calcular la localización de fallas en las líneas de transmisión de alto voltaje. Este algoritmo está basado en la modelación de las líneas defectuosas o propensas a fallar y también incorpora el método de Monte Carlo, para calcular la distancia a la falla y el tamaño del segmento de la línea donde existen cortos circuitos.

El segundo método basado en propagación, identifica la localización de la falla utilizando el tiempo de retorno de un pulso. Dentro de esta clasificación se tienen trabajos

como los de Martinez, 2003 [60], en donde utiliza el método de la propagación de la onda de la distancia de protección basado en patrones de reconocimiento con el PCA (Análisis de componentes principales) para localizar la falla de los dispositivos de protección de velocidad rápida en las líneas de transmisión. Este método da la posibilidad de caracterizar la forma de la onda frontal para fallas internas y externas de las líneas de transmisión protegidas. En el 2003, otra investigadora, Chanda [61], utilizó Análisis de multirresolución de ondas (MRA) para la localización de fallas. Ella utilizó EMTP para generar la señal de entrada en el dominio del tiempo y las ocho ondas Daubechies para transformar las 3 fases de corriente en la línea de transmisión por ambas terminales.

El tercer método corresponde a sistemas inteligentes, en dónde se utilizan diversas aproximaciones tal como sistemas expertos, lógica difusa y redes neuronales artificiales (ANN). Las últimas mencionadas, son muy atractivas debido a la rapidez computacional y por lo tanto, a la solución de una manera eficiente, lo cual es favorable en la detección de fallas debido a que se requiere de gran exactitud y velocidad. En 1997, Zhihong y Maun [62], aplicaron un algoritmo de ANN para seleccionar favores de pre-falla y superponer los voltajes y corrientes de todas las fases de las líneas de transmisión. Esto mapea la relación no lineal entre modelos de línea. Los resultados mostraron que se puede adaptar a sí mismo a variaciones muy grandes en la impedancia de la fuente en una terminal remota. En el 2000, Parushothama et. al [63], presentó una técnica de aprendizaje de ANN modificada para localización de falla y determinación de resistencia de falla donde una pequeña red neuronal es construida automáticamente sin el conocimiento previo del tamaño, profundidad y patrones de conectividad. Cuando el resultado es comparado con el algoritmo analítico y el algoritmo convencional MLP, se encuentra que es más exacto. En 1997, Song, Xuan y Johns [64], compararon estudios de cinco redes neuronales basadas en clasificadores de fallas para una serie de líneas de transmisión compensadas, llamados el clasificador BP de propagación hacia atrás, el clasificador FM, el clasificador RBF, el clasificador CF y el clasificador LVQ. Ellos concluyeron que los clasificadores RBF y CF eran los mejores candidatos. Kim y Park [65] desarrollaron ANNs jerárquicas para el diagnóstico de fallas en sistemas de potencia. Ellos usaron MLP para construir una estructura jerárquica para la detección de fallas. Diversos estudios son actualmente desarrollados para estudiar la detección de fallas en esta área. Un trabajo más reciente viene de Yeo et. al en el 2003 [66], que utilizó una red adaptiva combinada y un sistema de inferencia difuso (ANFIS) y los resultados, mostraron que podía detectar y clasificar fallas incluyendo fallas de impedancia baja (LIFs) así como fallas de impedancia alta (HIFs).

El método que se seleccionó para este proyecto cae en la tercera categoría, métodos de sistemas inteligentes.

2.1.5 Software MicroTran

El software MicroTran es una herramienta de simulación para redes eléctricas bajo condiciones transitorias. Las principales razones por las que se decidió utilizar este software es debido a la gran capacidad que tiene para manejar un número elevado de

elementos en redes eléctricas, pudiendo así, simular redes industriales, las cuáles poseen una gran cantidad de dispositivos, en muy poco tiempo. Entre algunas de sus características importantes y necesarias para este proyecto, se tienen: simulación de circuitos multifásicos, transformadores de una y tres fases, switches con cualquier cantidad de secuencias de apertura/cierre, determinación de condiciones iniciales por el usuario, obtención del estado estable de los fasores, entre otras. El software MicroTran comprende cuatro programas principales: mtDiagram, mtData, mtLine y mtPlot. En los siguientes párrafos se describirá su función. La estructura de la red eléctrica para su estudio, puede ser introducida por medio de un diagrama de la red eléctrica (mtDiagram) o por medio de un archivo de texto (mtData) con la información de los dispositivos utilizados, en forma de una tabla. La simulación de la red es corrida desde MS-DOS por el comando mtLine y crea un archivo de texto de salida (.dat) con la información del comportamiento del voltaje y/o corriente de cada uno de los nodos simulados, y un archivo que puede ser visualizado en el programa mtPlot como un gráfico (.plt), en donde se puede observar el diagrama de voltaje y/o corriente en estado transitorio de cada uno de los nodos simulados, así también como el diagrama de los fasores en estado estable de cada uno de ellos. (Ver Fig. 6).

2.1.6 Software HUGIN EXPERT 7.0

El software HUGIN es una herramienta que sirve para desarrollar e implementar soluciones de gestión inteligente del conocimiento. En este software se realiza la simulación de redes bayesianas (normales e híbridas) y diagramas de influencia, y a partir de los datos obtenidos ayuda al operario en la toma de decisiones, o en otras palabras, demuestra al usuario la probabilidad más grande de que un evento haya sucedido o pueda suceder, dada cierta evidencia.

La estructura de la red bayesiana puede ser realizada gráficamente o mediante algún lenguaje de programación (C, java, VisualBasic, etc.). La estructura gráfica de la red bayesiana en el software, se realiza igual que en el método tradicional, esto es: un círculo representa a una variable discreta, una flecha representa el grado de dependencia entre una variable y otra, y un círculo doble representa variables continuas. Una vez que ya se haya creado la estructura deseada, se procede a llenar las tablas de condición probabilística de cada nodo, es decir, la relación causa-efecto de todas las variables. Esta relación, como fue mencionado anteriormente, puede ser obtenida de los conocimientos previos del sistema o de bases de datos que se tengan almacenadas. Para finalizar, el programa simplemente se corre y se le introduce la evidencia deseada. De esta manera, el usuario tendrá la información necesaria para la toma de decisiones. (Ver Fig. 7).

La estructura de Red Bayesiana a través de lenguaje de programación, es más complicada y requiere de un manual especial para su realización.

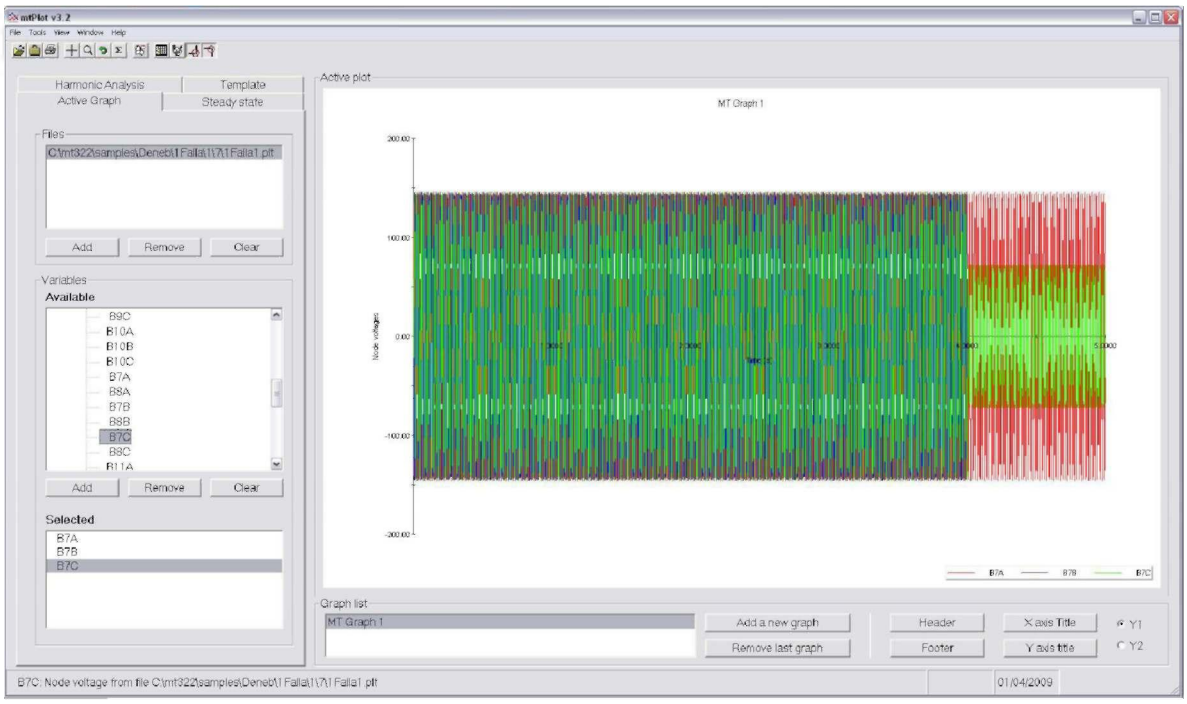

Figura 6: Programa mtPlot del software MicroTran

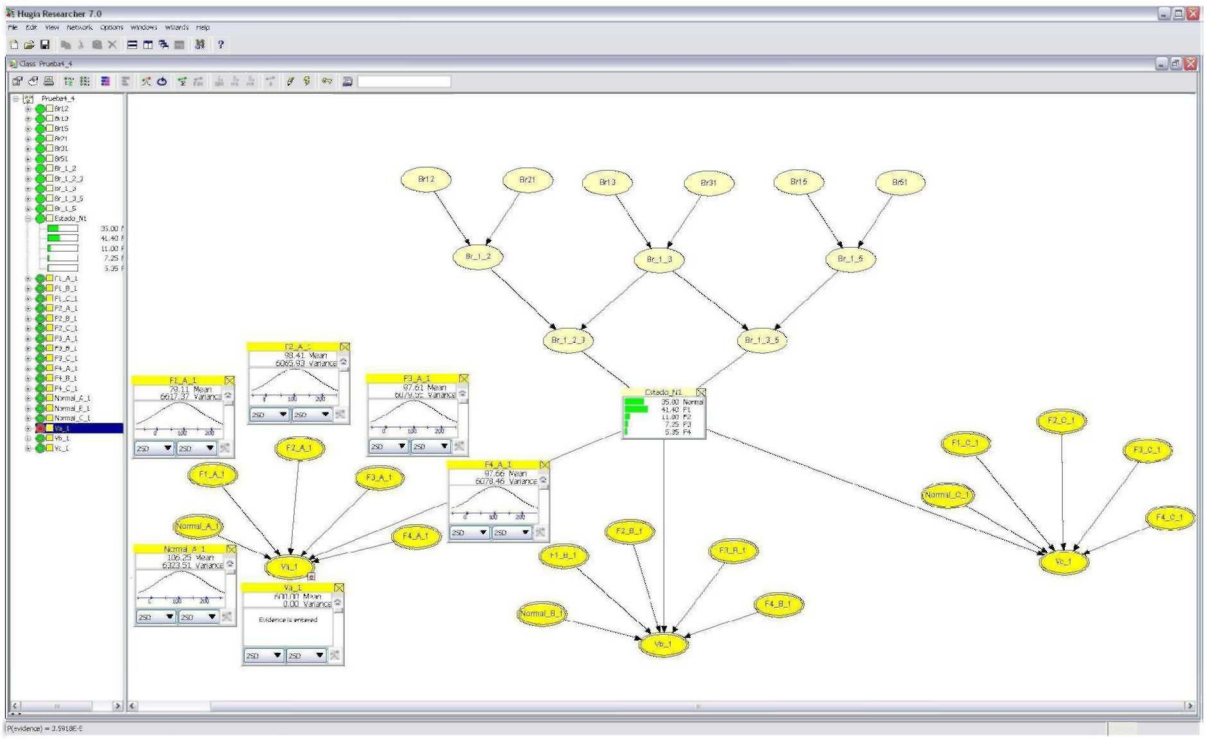

Figura 7: Modelo de RBH en HUGIN

CAPÍTULO 3
Experimentos

3.1 Sinopsis

En los capítulos anteriores se ha dado una explicación profunda sobre la metodología que se utilizará para resolver el problema planteado y un marco teórico suficiente para el entendimiento de lo que se realizará. El sistema básicamente cuenta con dos etapas, de las cuales una está destinada a la simulación, adquisición y acondicionamiento de los datos del comportamiento de la red eléctrica, mientras que la segunda etapa se encargará del diagnóstico de fallas a través de las redes bayesianas híbridas. En este capítulo se presentan los modelos realizados para la detección y diagnóstico de fallas, mediante los datos obtenidos de la red eléctrica. En la segunda sección se describirá el acondicionamiento de la información recopilada, así como también se dará un pequeño ejemplo de esta técnica. Los modelos obtenidos son enunciados en la tercera sección, al igual que la evaluación del funcionamiento del modelo propuesto.

3.2 Extracción de Rasgos Característicos de la señal: Acondicionamiento de señal

La red eléctrica utilizada para este caso de estudio particular, posee 24 nodos, cada uno con 3 fases que brindan información de los voltajes de la red al sistema de detección de fallas, lo que hace un total de 72 arreglos de datos con 5000 muestras cada uno (el software MicroTran, encargado de la simulación de redes eléctricas, realiza escenarios con este número de datos por default, esto es pruebas de 5 segundos con un muestreo de 1 ms), lo que demuestra la gran cantidad de información que se posee y la necesidad de acondicionarla de manera que se ocupe el menor tiempo posible para pasar a la siguiente etapa.

El software HUGIN encargado de la modelación de las RBH, necesita la media y la varianza para poder trabajar con datos continuos con distribución Gaussiana, por lo que la primera idea es realizar estos cálculos para toda la información obtenida; los resultados son mostrados en el Apéndice B. Analizando los datos obtenidos, se puede observar que todas las fases de los nodos poseen varianzas muy grandes y medias muy pequeñas, además, el mayor problema es la semejanza en los valores de los datos; ya que existen varianzas entre algunas medias de los 72 arreglos, que pueden llegar a ser de aproximadamente 0.0001, valor muy pequeño que producirá un mal funcionamiento en el diagnóstico de fallas, ya sea porque las probabilidades de inferencia sean tan pequeñas que los 4 decimales que el software utiliza, no las lograra diferenciar, o por la sensibilidad que pueden tener los nodos

correlacionados, en el momento de presentarse fallas simultáneas y múltiples, resultando en un modelo poco exacto y eficiente.

Debido a lo anteriormente dicho, la posibilidad de realizar índices de peso para cada nodo, por cada tipo de falla se convierte en una solución factible. Albano et al. en [67], elaboran una fórmula para crear un índice para voltajes de 3 fases no balanceados. Los índices de las tres fases se evalúan para cada período especificado con la siguiente fórmula:

$$S = 1 - \frac{d_a V_a - d_b V_b - d_c V_c}{3} \tag{21}$$

donde:

V_a, V_b, V_c : Magnitud del voltaje

d_a, d_b, d_c : Coeficientes que dan peso a cada fase

Las ventajas de utilizar este método, son las siguientes:

- Adoptando estos índices, el procedimiento es capaz de identificar correctamente la evolución de las perturbaciones y empezar la extracción característica de cada evento identificado y el número de fases involucradas en la falla para cada sub-evento [67].

- La cantidad de información se reduce a una tercera parte, para la siguiente etapa.

- Índice diferente para cada tipo de falla, en cada nodo.

- Varianza mayor a 0.0001 entre las medias de cada índice, lo que resulta en mayor facilidad para identificación de fallas.

Por último, solo para dejar en claro cómo es que los índices son calculados y utilizados en esta aplicación en particular, se da a continuación una pequeña descripción de su realización:

1. La manera en que las señales de voltaje son obtenidas de MicroTran, es en un vector de 5000 datos (equivalentes a 5 segundos de prueba, con un período de muestreo de 1 ms) por cada fase de cada nodo de la red.

2. Una vez que se tienen estos datos, por cada nodo se calcula un índice de falla con la ecuación 21, consiguiéndose 24 vectores de 5000 datos de índices de fallas, es decir, uno por cada nodo y cada muestreo de los datos obtenidos.

3. Para finalizar, simplemente se calcula el valor promedio de estos vectores, y de ahí se obtienen los índices de falla, que posteriormente serán introducidos al modelo de RBH.

Para mayor entendimiento, en la siguiente sección se da un ejemplo de lo aquí explicado.

3.2.1 Ejemplo

Dada la red eléctrica ya descrita, se escogieron los valores de *da = 500*, *db = 150* y *dc = 350*, valores encontrados experimentalmente y que demuestran que los resultados de las medias, están separados significativamente. La gráfica que muestra los índices que se obtuvieron para diferentes fallas en el nodo 1, se puede observar en la Fig. 8.

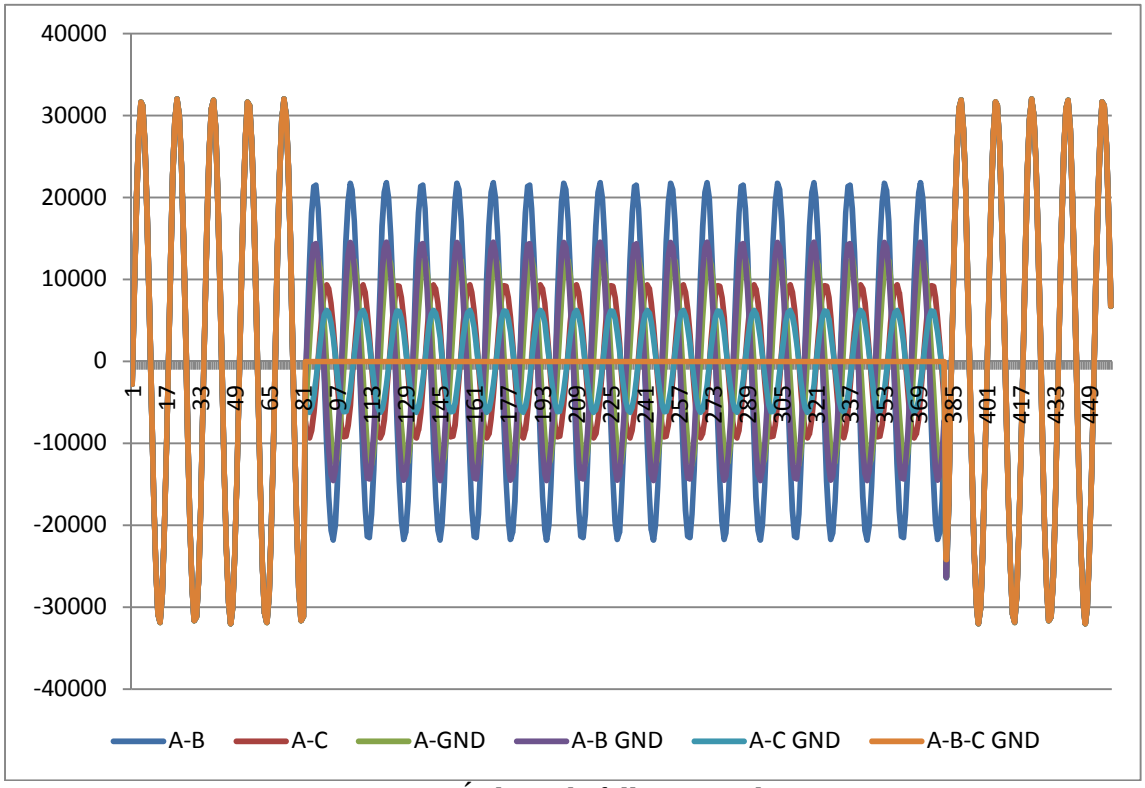

Figura 8: Índices de fallas en Nodo 1

Como puede observarse en la Fig. 8, antes de que ocurra una falla de cualquier tipo, el índice siempre es el mismo, por lo que no hay posibilidad de una detección de falla erróneamente. Una vez que la falla se presenta, los índices se encuentran suficientemente separados entre sí, para detectar el origen de la misma. Los valores de los índices en el nodo 1, son presentados en la Tabla 3.

En este nodo, la varianza entre las diferentes fallas no es muy pronunciada, llegando a un valor aproximadamente de 1.65, pero existen nodos en donde la varianza llega inclusive a 74.49, realizando la labor de identificación más sencilla (ver Tabla C.1, en Apéndice C).

Tipo de falla	*Índice correspondiente*
Normal	7.074697
AB	6.947467
AC	11.47697
BC	7.241442
A-Gnd	7.271375
B-Gnd	7.037488
C-Gnd	7.951017
AB-Gnd	7.138138
AC-Gnd	8.051015
BC-Gnd	7.816773
ABC-Gnd	7.917646

Tabla 3: Índices de falla para el nodo 1

3.2.2 Análisis de índices

Una vez concluidos los cálculos necesarios para la generación de todos los índices de los nodos, se procedió a analizar las relaciones que existen entre estos, y las consecuencias que acarrea una falla en determinado nodo para sus conexiones próximas.

Las primeras observaciones demuestran que el comportamiento de las diversas fases de los nodos eléctricos ante la presencia de fallas, es prácticamente el mismo, el cual puede observarse en la Fig. 5; sin embargo, realizando observaciones más a fondo, descubrimos que existen comportamientos extraños en determinados nodos. Generalmente cuando una falla se presenta, el comportamiento del nodo cambia, por el tiempo en que la carga de falla esté "conectada", sin embargo, una vez que ésta es retirada, los valores de los voltajes de las fases, regresan a su valor normal, sin embargo, en algunos nodos cuando cierto tipo de falla es presentado (comúnmente, falla línea a línea: B-C), adquiere una dinámica peculiar en donde el nodo no regresa a su valor inicial, aunque la carga de falla sea retirada. Un ejemplo de este tipo de comportamiento se encuentra en el nodo 7, mostrado en la Fig. 9.

La falla mostrada en la Fig. 9, es de tipo Línea a Línea entre las fases B y C del nodo 7, la falla entra a través de un interruptor programado para que se active en el intervalo de tiempo de 4 a 4.3 segundos; la prueba es realizada por una duración de 5 segundos, pero como se puede observar el sistema nunca se recupera después de que el interruptor se

desactiva, como se podría esperar. Casos como éste, existen varios dentro de la red, y perjudican el comportamiento y los índices de los nodos próximos.

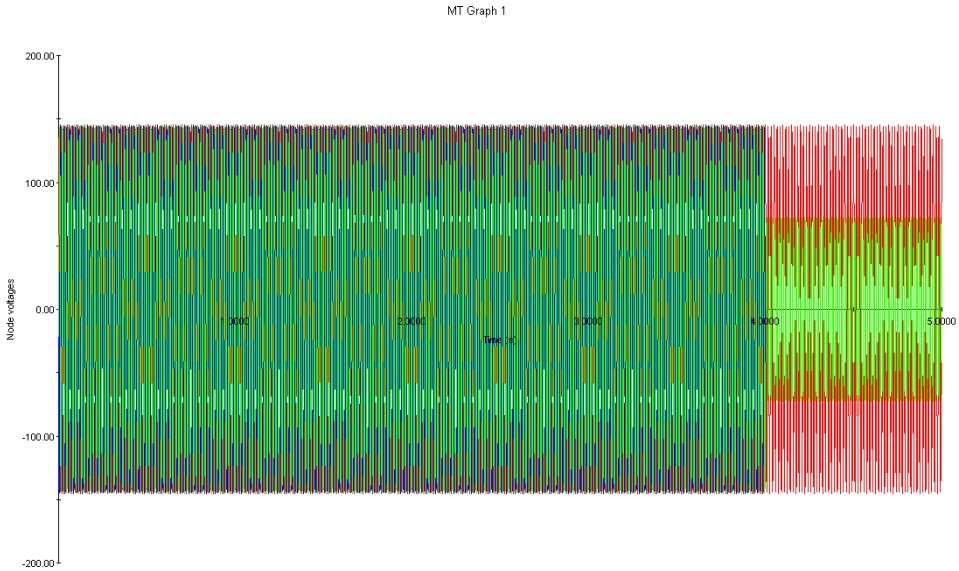

Figura 9: Falla Línea a Línea en Nodo 7

Realizando un estudio a fondo del impacto de este tipo de dinámica en la red, se concluye que, esta dinámica afecta los valores normales de otros índices de nodos en la red, por ejemplo, el nodo nueve tiene un valor normal de funcionamiento de 13.43652, al presentarse una falla del tipo B-C en el nodo 7, su valor aumenta en 3 unidades (16.31853), aunque éste no tenga ningún tipo de presencia de falla. Sabiendo que éste es el único tipo de consecuencia que ocasiona en la red, podemos trabajar en torno a estas dinámicas peculiares, debido a que todos los nodos presentarán cierto grado de variación en sus índices en el momento de tener fallas múltiples, por lo que, simplemente en los modelos de Red Bayesiana, estableceremos que si las probabilidades de que un nodo con esta dinámica presente ese tipo de falla, entonces los otros nodos se encuentran en estado normal.

Otra observación que se realiza en el momento de analizar los comportamientos de los índices de falla, es que existen también relaciones entre parejas de nodos muy perjudiciales para nuestro estudio, un caso en particular es el que se presenta entre el nodo 3 y el nodo 24, en donde si se presenta una falla en alguno de estos, repercute en un valor significativo en el otro. Estos valores son mostrados en la Tabla 4.

Como se puede observar en la Tabla 4, las fallas que se ocasionan en los nodos repercuten en el otro, bajando inclusive hasta 14 puntos al índice de su nivel normal.

El último tipo de relación problemática entre nodos existente en la red de estudio, es la presentada por los nodos 9, 10, 11 y 12. Cualquier falla que exista en uno de estos nodos, tiene consecuencias significativas en los otros tres, debido probablemente a la falta de generadores en estos y a la interconexión con nodos que en su mayoría no posee generadores, tienen valores muy pequeños o impedancias muy grandes. En la Tabla 5 se

muestran los valores del Nodo 9, como consecuencia de diferentes fallas en los nodos consecutivos.

Tipo de Falla	*Nodo 3*	*Nodo 24*
Normal	13.70147	12.2831
AB	23.66578	19.60348
AC	-1.4212	1.631141
BC	9.739763	8.888394
A-Gnd	15.05474	13.26746
B-Gnd	21.00561	17.0862
C-Gnd	5.331419	5.798242
AB-Gnd	20.12896	16.16016
AC-Gnd	10.38863	5.589166
BC-Gnd	10.38863	9.425444
ABC-Gnd	9.472488	8.469525

Tabla 4: Análisis de índices con reacción en cadena entre Nodo 3 y Nodo 24

Tipo de Falla	*Falla en 10*	*Falla en 11*	*Falla en 12*
Normal	13.43652	13.43652	13.43652
AB	21.19376	24.90014	21.96759
AC	11.67618	3.964854	4.608788
BC	13.2817	11.27396	11.5069
A-Gnd	17.05406	15.55048	15.74674
B-Gnd	18.23317	19.6408	19.47836
C-Gnd	11.35678	6.347704	6.837162
AB-Gnd	19.41687	19.32447	19.35656
AC-Gnd	13.07068	6.000892	6.691483
BC-Gnd	14.27013	10.11716	10.44824
ABC-Gnd	15.44854	9.773563	10.30402

Tabla 5: Relación de índices con reacción en cadena en Nodo 9 dado fallas en Nodo 10,11 y 12

Como se puede observar en la Tabla 5, si existen fallas en los Nodos 10, 11 y 12, pueden modificar el índice del Nodo 9 inclusive en 11 puntos. Situaciones similares suceden entre estos 4 nodos.

En este tipo de situaciones, en donde las fallas en ciertos nodos, influyen en la creación de los índices de falla de otros nodos, el valor de las probabilidades en el modelo de RBH tendrá el papel primordial, de descubrir cuál de estas fallas es la que se está presentando y cuáles nodos siguen estando en estado normal, aunque sus índices digan lo contrario.

Todos estos escenarios tienen que ser tomados en cuenta para la generación del modelo de RBH.

3.3 Modelos probabilísticos híbridos: RBH

Una vez que la primera etapa se encuentra completamente realizada, y los datos necesarios están acondicionados propiamente, se procede a realizar una propuesta de un modelo de red bayesiana híbrida para la detección de fallas de la red eléctrica. Se debe poner en claro, que los primeros 5 modelos realizados, fueron elaborados directamente a partir de los datos, sin embargo, del modelo 6 en adelante, las medias y varianzas utilizadas, fueron calculadas con el índice mencionado en la sección anterior.

3.3.1 Primer modelo: Descripción

La estructura del modelo probabilístico híbrido, es decir, la estructura de la Red Bayesiana Híbrida aquí propuesta, consta de tres partes claramente establecidas:

- la parte superior, en la cual se manejan los datos discretos, que son obtenidos a partir de los 68 interruptores de protección de la red eléctrica, y cuya función consiste en decirle al modelo que hay una falla presente

- la parte inferior, en la cual se trata a los datos continuos, obtenidos de las 3 fases de los nodos de la red, cuya función es la de obtener datos que identifiquen el tipo de falla y

- la parte media, en donde se conectan los datos discretos y continuos, con el fin de relacionarlos y obtener el tipo de falla detectada.

En la Fig. 10 se muestra el primer modelo establecido, con la estructura antes descrita.

Como se puede observar en la Fig. 10, la parte superior donde se trabajan los datos discretos, es algo complicada, y esto sucede debido a que cada interruptor de protección posee 3 estados de operación (OPEN, FAIL, OK), por lo que una combinación de *"n"* – interruptores, corresponde a $3^n \times m$ posibles soluciones, en donde *m* representa el número de estados que tenga el hijo de los interruptores de protección, que para algunos nodos (por ejemplo el 9), correspondería a 59049 posibles soluciones por estado del hijo (esto es *n=10* , es decir, $3^n = 3^{10}$ =59049, por cada *m* que se tenga), las cuáles serían muy difíciles de establecer para el programador en HUGIN. Debido a esto, se estableció que cada par de interruptores de protección tendría una tabla condicional de probabilidad, de manera que solamente existieran 9 posibles soluciones ($3^n = 3^2$) por estado de operación del hijo, las cuáles son fáciles de programar y no son confusas para el programador.

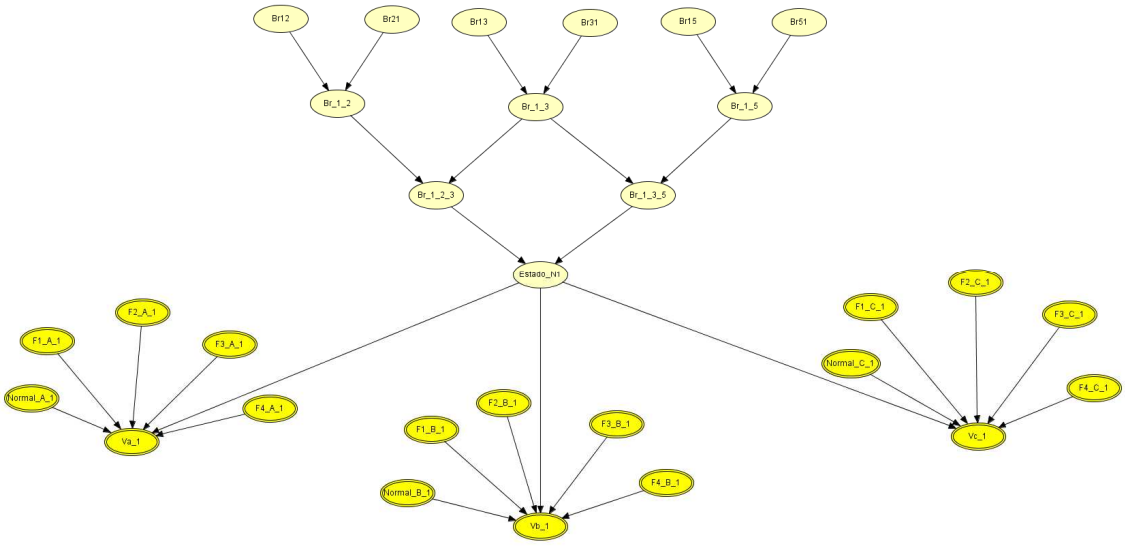

Figura 10: Primera estructura de RBH para la red eléctrica establecida

En la parte inferior, donde se trabaja con los datos continuos de los nodos de la red eléctrica, se puede observar que cada fase de un nodo está constituida por 5 padres continuos y 1 padre discreto. Los 5 padres continuos, se refieren a las medias y varianzas de cada determinada falla en determinada fase, incluyendo su funcionamiento normal. El padre discreto, da la misma probabilidad a todas las fallas (si es que los interruptores de protección indican la presencia de éstas indican la presencia de éstas) para que sean los nodos continuos los que realmente la identifiquen. En la Tabla 6 se muestra como ejemplo, la tabla de probabilidad condicional (TPC) de la fase A.

Estado Nodo 1	*Normal*	*F1*	*F2*	*F3*	*F4*
Media	-0.024879	-0.031961	-0.02526	-0.02548	-0.02547
Normal A1	1	1.28	1.02	1.02	1.023
F1 A1	0.78	1	0.79	07972	0.7969
F2 A1	0.98	1.2652	1	1.008	1.008
F3 A1	0.976	1.2543	0.9913	1	0.9996
F4 A1	0.9767	1.2548	0.9917	1.003	1
Varianza	7774.77	7423.59	7317.31	7308.25	7308.25

Tabla 6: TPC de la fase A del Nodo 1

Los pesos que se dan en la TPC de la fase A, corresponden al valor de la media establecido por el estado de operación del nodo *"Estado Nodo 1"* dividida entre la media de cada uno de los padres continuos del nodo hijo, es decir, estado Normal A1, F1 A1, F2 A1, F3 A1 y F4 A1. En donde *"Normal"* representa la media del nodo cuando no existen fallas presentes, *"F1"* denomina la media del nodo cuando existe la falla línea a línea, *"F2"* cuando es una fase a tierra, *"F3"* cuando representa dos fases a tierra y *"F4"* cuando

se habla de tres fases a tierra; la letra y número *"A1"*, definen que se trata del Nodo 1 y de la fase A. La varianza establecida, es la correspondiente al estado de operación del padre discreto, es decir *"Estado Nodo 1"*.

En la parte media se encuentra el nodo con el nombre de *"Estado Nodo 1"*, que significa estado del nodo 1 de la red eléctrica, y en él se van a relacionar los datos discretos y los continuos. A este nodo llega la información de la parte superior, estableciendo si hay falla o no a partir de datos recibidos de los interruptores de protección, y la información que entre en la parte inferior, nos dice con respecto a qué media está más próxima la información obtenida del nodo. De ésta forma, en la parte media se establece el tipo de falla que hay en el nodo estudiado.

Debe observarse en la Fig. 10, que el nodo discreto es padre del nodo continuo, y esto se debe a que las reglas del HUGIN establecen que no es aceptable hacerlo de manera inversa. Es probable que el resultado fuera más lógico y acertado si se realizará de la manera inversa, sin embargo, realizándolo de esta forma, presenta resultados satisfactorios.

3.3.2 Evaluación Primer Modelo

Los resultados son insatisfactorios; aunque el modelo "detecta" cierto tipo de fallas, siempre se ve inclinado a diagnosticar el mismo tipo de falla en cada nodo, debido a:

1. El peso mayor en la TPC de cada fase, da una mayor probabilidad a este tipo de falla.

2. Esto se incrementa, al observar que los pesos que se encuentran en esta tabla, son muy pequeños en comparación a la varianza establecida, por lo que un pequeño cambio en los datos continuos no genera ningún cambio significativo en la probabilidad final para detectar la falla.

3. Otra pequeño defecto de este modelo, es que las medias están separadas por unas cuantas milésimas (algunos de hasta 0.0001), lo cual dificulta que por el manejo de los decimales en el software HUGIN, pueda detectar un solo tipo de falla, es decir, el redondeo de los decimales genera que dos o tres tipos de fallas tengan las mismas probabilidades al final.

4. Por último, existe una pequeña falla en el tratamiento de los datos discretos; como se puede observar en la figura 9, existen nodos intermedios entre los interruptores de protección y el nodo "Estado Nodo 1". Estos nodos intermedios carecen de significado y también le dan una mayor probabilidad a los interruptores 13 y 31 (en el caso del nodo 1, fase A) de contener siempre una falla, debido a que estos dos tienen dos veces el peso de los otros en la siguiente etapa, al entrar dos veces a los siguientes nodos intermedios.

3.3.3 Segundo Modelo: Descripción

En el segundo modelo, se trató de resolver el punto 4 anteriormente mencionado, mediante la eliminación de uno de los nodos intermedios, de manera que el Br_1_3 no diera una probabilidad más alta de falla, al momento de la detección de la misma. El resultado se muestra en la Fig. 11.

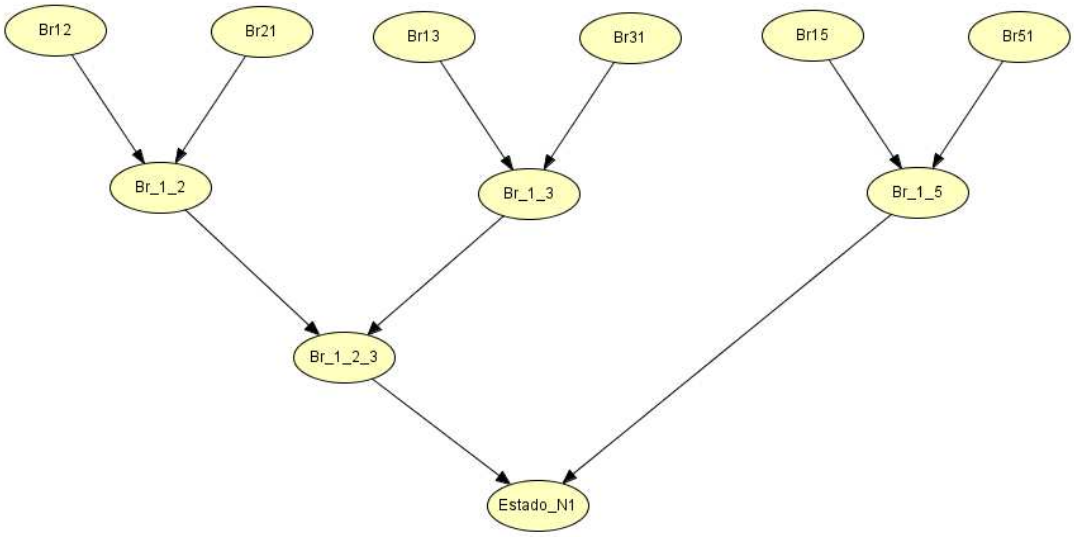

Figura 11: Corrección en parte digital del primer modelo

La estructura que se muestra en la Fig. 11, no es del todo eficiente, debido a que la probabilidad que da el *"Br_1_5"* para la identificación de la falla, es del doble de los nodos *"Br_1_2"* y *"Br_1_3"*, ya que existe un nodo intermedio más entre ellos, antes de llegar al nodo *"Estado_N1"*.

La Fig. 11, no se probó en el modelo completo, debido a que se observó una mejor manera de realizarlo, presentado en el siguiente modelo.

3.3.4 Tercer Modelo: Descripción

En el siguiente modelo, se respeta la estructura establecida en el primer modelo, consistente de 3 partes, una para tratar datos discretos, otra para tratar datos continuos y la última para relacionarlos; sin embargo, la parte superior (datos discretos) sufre un pequeño cambio, que le da más significado a los nodos intermedios. El modelo se presenta en la Fig. 12.

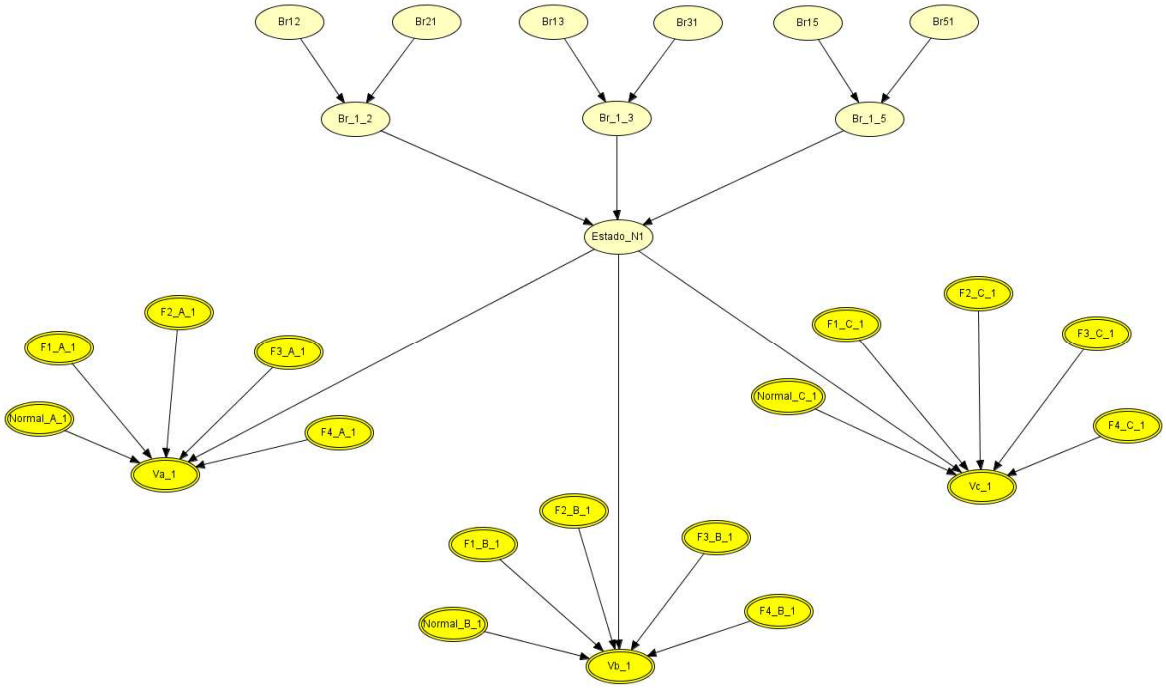

Figura 12: Tercera estructura de RBH para la red eléctrica establecida

Los datos de las TPC, son iguales a los ya mencionados, con la única diferencia de que el nodo denominado *"Estado Nodo 1"* posee 27 posibilidades por cada estado de operación ($3^n=3^3$), siendo aún un número manejable para el programador. Sin embargo, este modelo presenta una ventaja sobre el anterior, y es que los nodos intermedios entre los interruptores de protección y el nodo de *"Estado Nodo 1"* se reducen a uno solo, teniendo así un paso más directo de la información y un mejor entendimiento de este suceso.

3.3.5 Evaluación Tercer Modelo

Los resultados presentados en este tercer modelo fueron insatisfactorios y parecidos a los del primer modelo, debido a que el funcionamiento interno es el mismo. Entre los puntos importantes de este modelo, tenemos:

1. En cada nodo, existe una clara inclinación a la detección de una determinada falla, debido a los pesos establecidos en el TPC.

2. La varianza es muy grande, en comparación con las medias establecidas para cada fase, dificultando así la correcta detección de la falla.

3. El problema en la parte digital mencionado en el primer modelo, ha sido resuelto, quitando nodos intermedios a la estructura.

3.3.6 Cuarto Modelo: Descripción

Al observarse con los modelos anteriores que la modificación de la estructura de la parte discreta en los modelos propuestos, tenía un impacto insignificante sobre la detección de las fallas, se decidió intentar cambiar la estructura del tratamiento de los datos continuos, agregando un nodo continuo, de manera que en él, se obtuviera un resultado general compuesto de las tres fases de voltaje de cada nodo de la red eléctrica, antes de entrar al nodo *"Estado Nodo 1"* para detectar finalmente la falla.

La TPC del nodo 1, se muestra en la Tabla 7. Las abreviaciones *"Va 1, Vb 1, Vc 1"* se refieren a los valores de los voltajes de las fases A, B y C del Nodo 1, respectivamente.

Estado Nodo 1	*Normal*	*F1*	*F2*	*F3*	*F4*
Mean	0.00113433	0.0213	0.018049	0.018119	0.018119
Va 1	21.9347	1.5005	1.3995	1.4062	1.4061
Vb 1	11.5522	0.567	0.5796	0.5775	0.5776
Vc 1	10.3603	0.9325	1.0208	1.0163	1.0163
Varianza	7309.87	7419.71	7312.89	7309.87	7309.87

Tabla 7: TPC del Nodo *"Nodo1 3 fases"*

Los datos de cada estado de operación del nodo *"Estado Nodo 1"*, fueron obtenidos a partir del análisis y combinación de las medias y varianzas de los datos de cada fase obtenidos a través de la simulación en MicroTran. Los pesos que tienen las 3 fases para cada estado de operación fueron obtenidas al dividir el valor de la media de cada fase en cada estado de operación, entre la media de las tres fases combinadas.

El modelo gráfico probabilístico híbrido, se presenta en la Fig. 13.

En la Fig. 13 se puede observar, como la parte discreta se ve reducida, mientras la parte de tratamiento de datos continuos se ve afectada con la introducción de un nuevo nodo. Cabe mencionar que a diferencia de los modelos anteriores los nodos continuos entran al nuevo nodo, y no viceversa, esto asegura, que las 3 fases se integren al nodo. Las probabilidades de la parte discreta también son insertados en el nuevo nodo, haciendo de este el nuevo comunicador entre ambas partes, aunque el resultado sobre la detección de fallas, aún recae sobre el nodo discreto *"Estado Nodo 1"*, debido a que los nodos continuos sólo presentan como resultado una media y una varianza y no una probabilidad sobre las fallas establecidas.

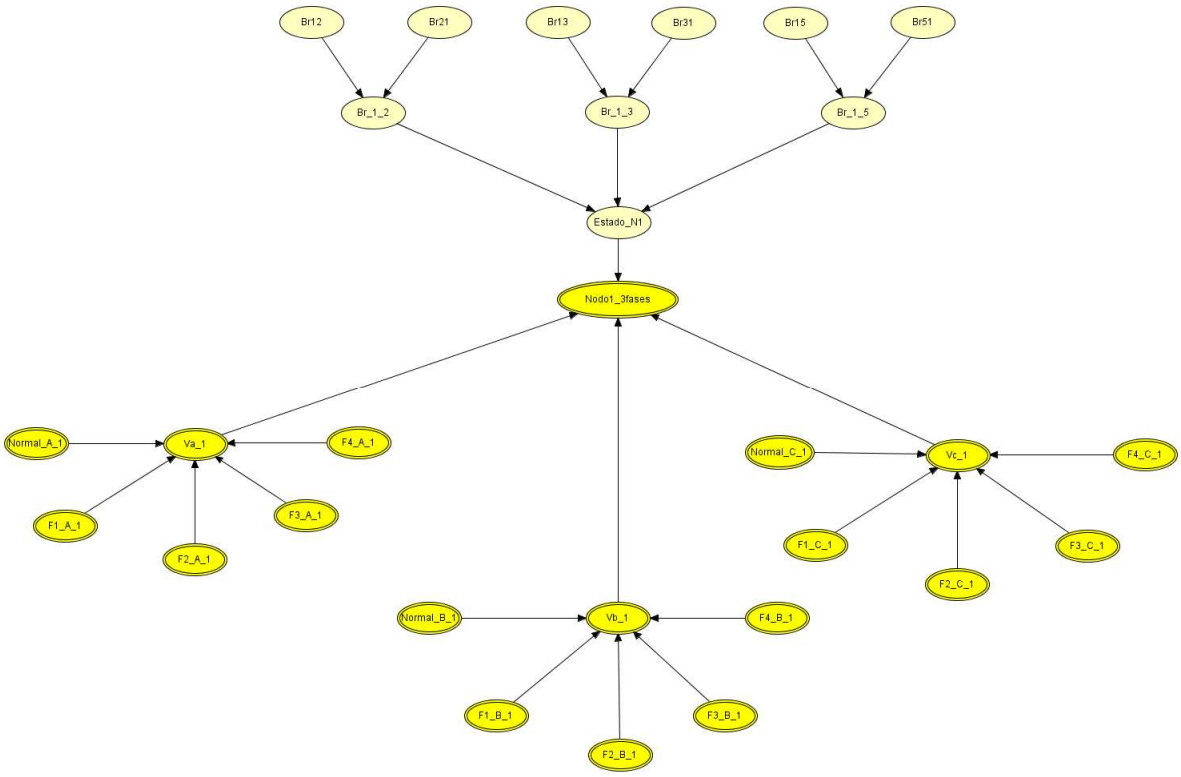

Figura 13: Cuarta Estructura de RBH para la red eléctrica establecida

3.3.7 Evaluación Cuarto Modelo

Al realizarse diversos estudios con este modelo, se obtuvieron resultados insatisfactorios. Entre los puntos importantes a nombrarse, están los siguientes:

1. Las varianzas establecidas en este modelo y en todo modelo que posea nodos continuos como padres, es de suma importancia, debido a que esta se combina en los nodos hijos, en el sentido, en que si una de ellas es muy grande, el peso de la probabilidad será muy pequeña en el siguiente nodo, haciendo que los cambios en los valores de las medias, tenga un peso pequeño e imperceptible para las probabilidades resultantes, trayendo como consecuencia una nula detección del tipo de falla establecido. Un intento de solución para este problema, es el establecimiento de varianzas pequeñas en los nodos de las 3 fases, para que la combinación genere densidades de probabilidades mayores, sin embargo, para obtener varianzas que sean lo suficientemente pequeñas para detectar un cambio en las medias, algunas veces establece un problema de

densidad en los nodos, haciendo para este en nuestro caso, un problema sin solución.

2. Se nota en esta estructura, que la inserción de datos a los 3 nodos continuos inferiores, no produce ninguna reacción para el nodo encargado de analizar el tipo de falla presentado en la red eléctrica, sin embargo, la inserción de información en el nodo continuo, en el cual se supone se combinan las 3 fases continuas inferiores, produce una detección de fallas, más satisfactoria, que los modelos anteriormente probados, aunque no del todo correcta.

3. A partir del punto anterior explicado, se crea la teoría sobre una estructura de RBH más sencilla. Probablemente, un modelo más sencillo, llegaría a detectar las fallas en la red eléctrica elegida.

3.3.8 Quinto Modelo: Descripción

Después del cuarto modelo, se pretendió realizar una estructura de Red Bayesiana Híbrida más simple para la detección de las fallas en la red eléctrica estudiada; sin embargo, el modelo seguiría teniendo 3 niveles: uno para el procesamiento de datos digitales, otro para el procesamiento de datos analógicos y un tercero capaz de comunicar los dos niveles anteriores.

El modelo propuesto se muestra en la Fig. 14.

Como se puede observar en la Fig. 14, se intentó realizar un modelo sencillo, en donde los datos discretos y análogos entraran directamente al nivel medio; por lo tanto, el nodo del nivel medio fue creado como un dato análogo, para que éste pudiera ser hijo de los datos de entrada mencionados.

La forma en que los datos digitales entran directamente en el nodo medio para ser tratados, ya había sido propuesta en modelos anteriores; sin embargo, el mayor cambio que aquí se puede observar, es la forma en que los datos análogos entran al modelo. En este modelo los datos análogos, es decir, las fases de los voltajes leídos en los nodos de la red eléctrica deseada, entran como una sola entrada y no como una señal compuesta por todas las diferentes posibilidades que se pueden leer en cada nodo. Para poder realizar esto, los datos de cada nodo son tratados antes de entrar en la Red Bayesiana aquí mencionada, mediante la fórmula establecida en la sección 3.2, en donde se explica, más a detalle, la manera de acondicionar la señal de los nodos eléctricos.

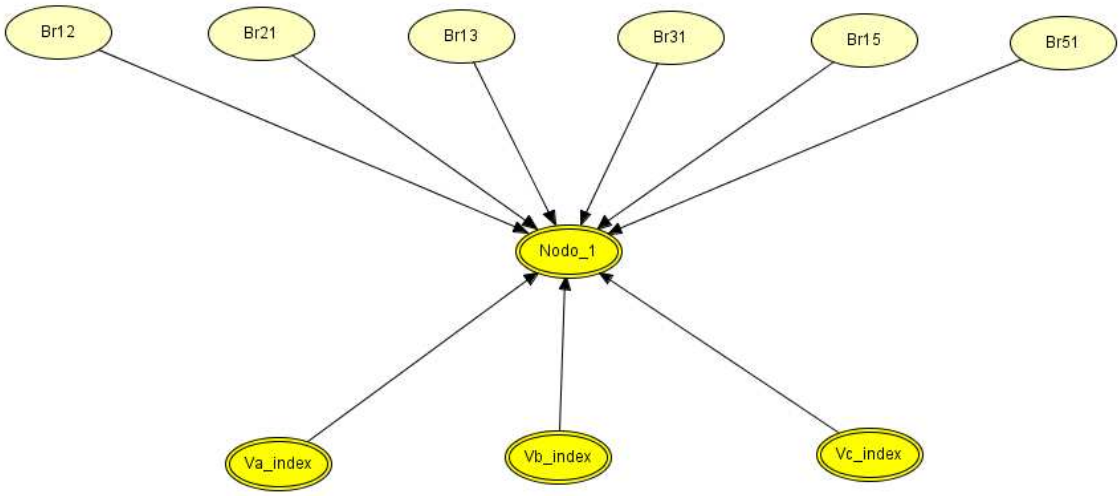

Figura 14: Quinta Estructura de RBH para la red eléctrica establecida

Cabe mencionar, que este acondicionamiento de señal, es utilizado por primera vez en este modelo, debido a las siguientes razones:

1. Se buscaba realizar un manejo más sencillo de los datos análogos

2. Se buscaba tener un procesamiento más rápido de los mismos

3. En los modelos anteriores, se observó que representaba un problema que cada nodo continuo estuviera compuesto por varios nodos análogos, debido a que las varianzas debían ser muy pequeñas, para crear un peso en una probabilidad lo suficientemente grande para que detectara algún tipo de falla. La varianza en los nodos individuales de las fases, si podía ser calculado, mientras que el siguiente nodo intermedio solo podía ser aproximado, y las mediciones de la conjunción de las 3 fases muchas veces presentaba variaciones muy pequeñas en las lecturas de los voltajes leídos en la red eléctrica, causando que no existiera una detección de falla en todo el modelo.

La media de los nodos se establece en la Tabla 3, y la varianza de cada uno de los nodos eléctricos varía dependiendo de fallas presentadas en otros nodos, la cercanía a un transformador, el tamaño de la falla, entre otras razones.

3.3.9 Evaluación Quinto Modelo

Como se mencionó anteriormente, la forma en que los datos digitales entran al nivel medio en este modelo, ya había sido considerada, y la problemática principal de esta

estructura, es el número de combinaciones necesaria para la programación de las probabilidades por cada renglón; y debido a que no existen niveles intermedios en la forma de procesar los datos digitales y los datos análogos entran también directamente al nivel medio, se requería programar 59049 posibilidades por 5 renglones en total. El reto de programar este número de probabilidades, ya se había considerado y se había aceptado, sin embargo, el tener un dato análogo como nivel intermedio nos planteaba también la problemática de tener que crear una media y una varianza para cada una de estas posibilidades, lo cual no se podía realizar, o requería una cantidad de tiempo muy grande para su aproximación, llegándose a la conclusión de no poderse realizar estudios con este modelo debido a su complejidad.

En la Tabla 8 se muestran 9 posibilidades de las 59049 que se tenían que realizar, para que el usuario pueda ver por sí mismo, la magnitud del problema que presentaba este modelo.

Br51	*Open*								
Br15	*Open*								
Br31	*Open*								
Br13	*Open*								
Br21	*Open*			*Fail*			*OK*		
Br12	*Open*	*Fail*	*OK*	*Open*	*Fail*	*OK*	*Open*	*Fail*	*OK*
Media	1	1.3	1.7	1	2.3	2	1	5	8
Índice Va	0	0	0	0	0	0	0	0	0
Índice Vb	0	0	0	0	0	0	0	0	0
Índice Vc	0	0	0	0	0	0	0	0	0
Varianza	0.1	0.2	0.1	0.3	1	0.2	0.1	2	3

Tabla 8: TPC del Nodo *"Nodo 1"*

El segundo error de este modelo, el cual constituye el problema principal de esta estructura es que no detecta ningún tipo de falla. Este modelo simplemente elabora un índice total del nodo estudiado, sin dar ningún tipo de información adicional. Este error, es completamente de diseño.

3.3.10 Sexto Modelo: Descripción

En el siguiente modelo se pretendió preservar el concepto de un diseño sencillo, pero corrigiendo los errores del modelo pasado. Por lo tanto, se agregó un nodo discreto en la estructura, el cuál sería encargado (como en modelos pasados) de darle peso a las diferentes tipos de fallas, mientras que en el nodo continuo establecido en el modelo anterior como nivel medio, simplemente se comportaría como un creador de un índice total del nodo de la red eléctrica.

El modelo se muestra en la Fig. 15.

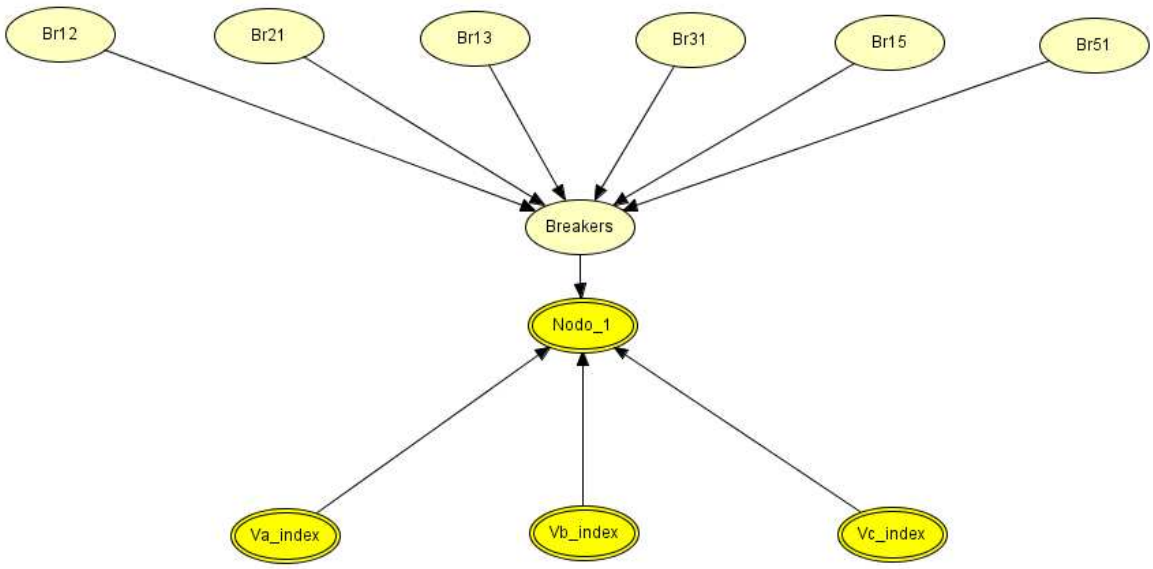

Figura 15: Sexta Estructura de RBH para la red eléctrica establecida

Como se puede observar en la Fig. 15, el procesamiento de las señales discretas será realizado como en el modelo anterior, con la única diferencia de la adición del nodo discreto *"Breakers"* (interruptor de protección), cuyo funcionamiento ya fue explicado, el cual pasa los datos recibidos directamente al *"Nodo 1"*, en donde el índice total del nodo eléctrico es calculado, es decir, en éste se describirán las medias y varianzas totales (tres fases en un sólo índice) que dan como resultado la presencia y ausencia de fallas en el nodo. En la Tabla 9 se muestra la TPC del *"Nodo 1"*.

Breakers	*Normal*	*Falla 1*	*Falla 2*	*Falla 3*	*Falla 4*
Media	-0.006075	-0.010477	-0.0006276	-0.007051	-0.006918
Índice Va	-0.333	-0.333	-0.333	-0.333	-0.333
Índice Vb	0.333	0.333	0.333	0.333	0.333
Índice Vc	0.333	0.333	0.333	0.333	0.333
Varianza	1	1	1	1	1

Tabla 9: TPC del Nodo *"Nodo 1"*

Como se puede observar en la Tabla 9, los valores de los pesos de los índices de las tres fases de voltaje en todas las opciones, es igual, debido a que simplemente estamos creando el índice total del nodo (a partir de la fórmula mencionada en la parte 3.2 Acondicionamiento de señal) y sumándoselo al valor de la media de cada una de las diferentes estados en los que puede estar determinado nodo. Hay que mencionar que en la Tabla 9, la etiqueta *"Normal"* corresponde a la representación del Nodo en un estado sin fallas, *"Falla 1"* representa la falla línea a línea, *"Falla 2"* denota la falla de una fase a tierra, *"Falla 3"* comprende la falla de dos fases a tierra y *"Falla 4"* define a la falla de 3

fases a tierra. La estrategia aquí desarrollada, para establecer una probabilidad mayor en el estado que se tiene en la red eléctrica, es la siguiente:

1. Se establece el estado de todos los *"Br's"*, así también como se introducen los valores de cada una de las fases y se crea el índice total.

2. Este valor se le resta a la media de cada uno de las medias establecidas para cada estado, de manera, que la media más pequeña después de esta operación es la opción más probable del estado real del nodo eléctrico.

3. El valor de la respuesta obtenida en el punto anterior, es restada a 1, de manera que genere un valor más alto que el de las demás probabilidades y señale el estado adecuado.

Debido a la estrategia mencionada, el valor que se dio en la media de cada estado en el *"Nodo 1"*, es *1 – Valor real de la media en el estado establecido*.

El nodo discreto *"Breakers"*, posee una gran importancia en este modelo, ya que además de ser un nodo que resuelve problemas anteriormente obtenidos, será el nodo encargado de decir al usuario si existe o no una falla en el nodo eléctrico y de qué tipo es.

3.3.11 Evaluación Sexto Modelo

A pesar de que en este modelo se agregó un nodo más para la disminución del cálculo de medias y varianzas en el nodo intermedio, el nuevo nodo agregado también poseía 5 renglones por 59049 probabilidades a programar, aunque ahora discretas. En la Tabla 10, se muestra el contenido del nodo *"Breakers"* (interruptores de protección).

Esta tabla nos demuestra, que aunque se resolvió el problema de la detección de falla en el nodo, se sigue teniendo una gran cantidad de datos a programar en el TPC, por lo tanto, no se realizaron estudios con este modelo y se prosiguió a conseguir una forma de reducir el número de probabilidades a calcular en el nodo "Breakers".

3.3.12 Séptimo Modelo: Descripción

La idea principal de este modelo, es corregir los errores de los 2 modelos pasados, pero sin perder la sencillez del mismo; por lo que, se agregó un nodo discreto más, de manera que el nodo *"Breakers"* sólo nos diera dos posibilidades finales, es decir, este nodo, solamente nos pudiera decir si en conjunto todos los Br's funcionaban correctamente o había una falla, reduciendo el número de renglones del TPC a dos, facilitando así su

programación y el nuevo nodo fuera el encargado de darle peso a todas las posibles fallas que se pudieran presentar en el nodo eléctrico de la red.

La estructura del séptimo modelo es mostrada en la Fig. 16.

Br51	*Open*								
Br15	*Open*								
Br31	*Open*								
Br13	*Open*								
Br21	*Open*			*Fail*			*OK*		
Br12	*Open*	*Fail*	*OK*	*Open*	*Fail*	*OK*	*Open*	*Fail*	*OK*
Normal	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002
Falla 1	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495
Falla 2	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495
Falla 3	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495
Falla 4	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495	0.2495

Tabla 10: TPC del Nodo *"Breakers"*

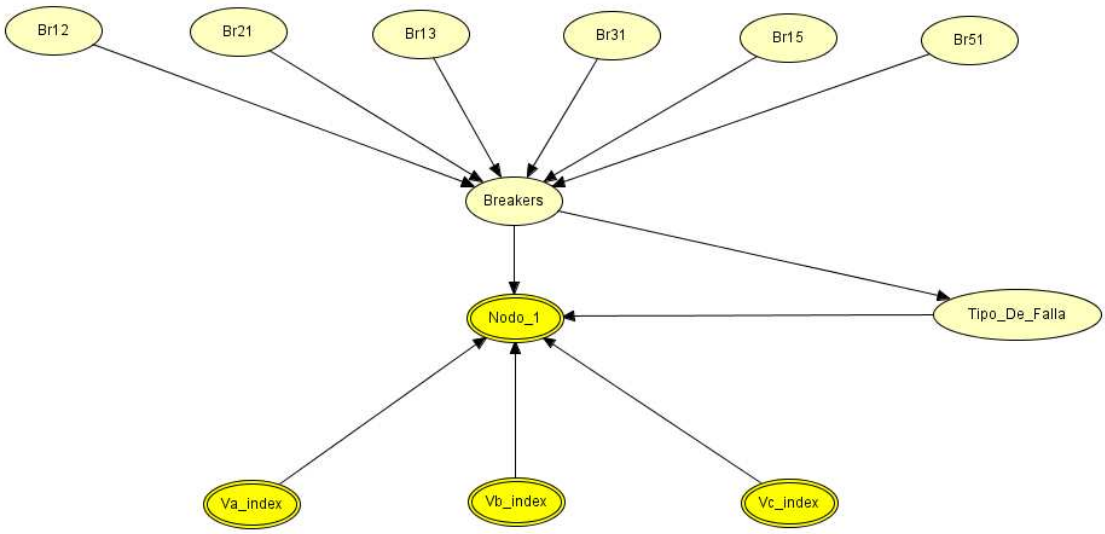

Figura 16: Séptima Estructura de RBH para la red eléctrica establecida

Como puede observarse en la Fig. 16, el nuevo nodo discreto denominado *"Tipo de Falla"*, dará el peso de las posibles fallas que se pudieran presentar, dependiendo del estado del padre de éste, es decir, dependiendo del estado Normal o Falla que se presente en el nodo *"Breakers"*.

Otro cambio significativo en este modelo, es la estrategia que se siguió para desarrollar el TPC del nodo *"Nodo 1"*. Debido a algunas pruebas que se hicieron en modelos intermedios entre el sexto y el séptimo modelo aquí presentados (ver sección 3.3.16 Otros modelos), se llegó a la conclusión de que aunque la estrategia anteriormente planeada,

hubiera servido para otro tipo de programación, para redes bayesianas no lo hace, debido a que el resultado que se daba en el nodo de identificación del tipo de falla, siempre se veía inclinado a un cierto tipo de falla. Por lo que se regresó a la idea principal, de simplemente poner las medias calculadas de todos los datos obtenidos con y sin fallas, dependiendo de los eventos pasados en los padres del mismo nodo. La TPC se muestra en la Tabla 11.

Breakers	*Normal*					*Falla*				
Tipo de Falla	*Normal*	*Falla 1*	*Falla 2*	*Falla 3*	*Falla 4*	*Normal*	*Falla 1*	*Falla 2*	*Falla 3*	*Falla 4*
Media	7.07	0	0	0	0	0	11.47	7.27	8.05	7.91
Índice Va	-0.33	-0.33	-0.33	-0.33	-0.33	-0.33	-0.33	-0.33	-0.33	-0.33
Índice Vb	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33
Índice Vc	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33	0.33
Varianza	1	1	1	1	1	1	1	1	1	1

Tabla 11: TPC del Nodo *"Breakers"*

En la Tabla 11 se puede observar, que si el nodo *"Breakers"* da como resultado el estado normal, entonces la media que se escribe en combinación con el estado Normal del nodo *"Tipo de Falla"* es la calculada de los datos obtenidos donde todo funciona, mientras que a las medias de las fallas, se les da un valor muy bajo, poco probable o no se llenan, debido a que la probabilidad de que salga este estado es muy bajo o despreciable. Por lo tanto, pasa lo contrario si el nodo *"Breakers"* da como resultado el estado de Falla.

En este modelo, el nodo encargado de decir al usuario que si existe o no alguna falla en el nodo eléctrico, y cuál es, es el denominado *"Tipo de Falla"*.

3.3.13 Evaluación Séptimo Modelo

Se realizaron diversas pruebas a este modelo, y a continuación se presentan los puntos más destacados del mismo:

- Siguen existiendo problemas con la varianza en el *"Nodo 1"*, debido a que este nodo está conformado de los datos continuos de las 3 fases de voltaje del nodo eléctrico. Si se escriben las varianzas apropiadas en los nodos *"Índice Va"*, *"Índice Vb"* y *"Índice Vc"*, la varianza total en el Nodo 1, es una varianza conjunta, mayor que las varianzas individuales, por lo que en el momento en el que cambian los datos insertados en la RBH, el cambio no es registrado como una falla, sino como una simple variación en la media que cae dentro de los márgenes establecidos por la varianza total. Si se escriben varianzas más pequeñas, en los índices individuales, genera un error en la varianza total debido a la densidad de la misma.

- Se observó en las pruebas realizadas a este modelo, que si los datos continuos son acondicionados antes de entrar a la RBH, es decir, si los datos continuos de las tres fases del voltaje, son tratados y unidos en un solo índice total antes de entrar al modelo, y este índice es directamente colocado en el nodo *"Nodo 1"*, la detección de fallas que se realiza, es posible y correcta.

3.3.14 Octavo Modelo: Descripción

El último modelo de esta sección, se muestra en la Fig. 17.

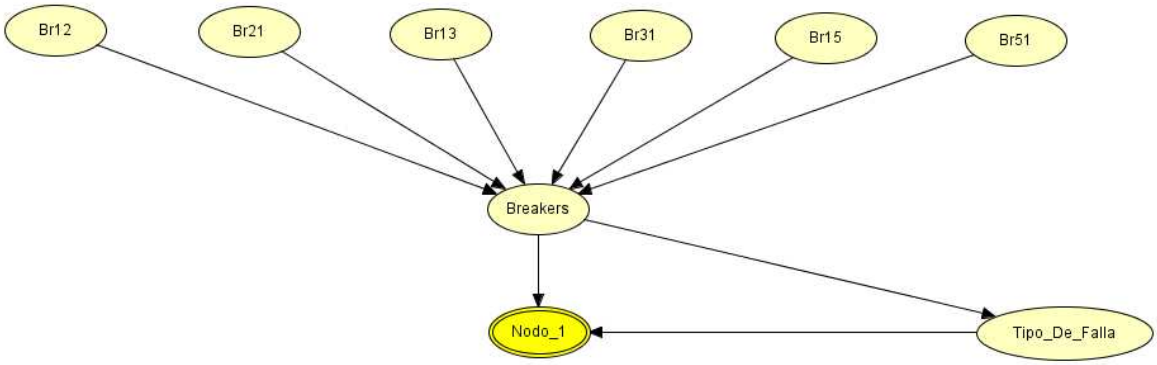

Figura 17: Octava Estructura de RBH para la red eléctrica establecida

Como se puede apreciar en la Fig. 17, el único cambio realizado en este modelo, es la eliminación de los nodos continuos padres del *"Nodo 1"*, de manera que en este modelo, se tiene que obtener un índice total de las 3 fases de voltajes leídos de la red eléctrica, y posteriormente dar ese dato a la RBH, para que se pueda realizar la detección de fallas.

3.3.15 Evaluación Octavo Modelo

Diversas pruebas realizadas a este modelo resaltan los siguientes puntos:

- La detección de fallas es correcta para cada nodo.

- El alcance de la detección de fallas nos presenta inclusive, no sólo el tipo de falla, sino también en cuáles fases del nodo de la red eléctrica se presenta el problema.

- La varianza para cada nodo es diferente, dependiendo del grado en que se afecte la media de este, a partir de fallas en otros nodos.

- Para presentar resultados completos, se tiene que realizar la conexión de todos los nodos de la red, establecer las interconexiones entre ellos (afectación en la creación de índices de falla en nodos vecinos, debido a presencia de ciertas fallas en algunos nodos) y realizar pruebas.

3.3.16 Otros Modelos

Cabe mencionar, que entre un modelo y otro de los aquí presentados, algunas veces se crearon otras estructuras con pequeñas modificaciones, que no fueron lo suficientemente significativas para reportarse como modelos propuestos. A continuación se mencionan dos.

En la Fig. 18, se muestra un intento de disminuir renglones de la TPC en el nodo *"Breakers"* (interruptores de seguridad), mediante la inserción de un nodo continuo denominado *"Estado Nodo 1"*. Este modelo falló, debido a que como ya se mencionó varias veces en este texto, las varianzas de los nodos continuos presentan un reto y un problema en el momento de realizar la detección de fallas; en esta estructura en particular, el tener 3 niveles de nodos continuos, daba como resultado una varianza muy grande, incapaz de detectar fallas ante el cambio de las medias insertadas al modelo.

Sin embargo, este modelo no fue del todo inservible, ya que nos dio como alternativa disminuir los renglones de la TPC del nodo *"Breakers"* mediante la inserción de un nodo discreto, así también como nos ayudó en la eliminación de la estrategia establecida en el sexto modelo (sección 3.3.10), al realizar diversas pruebas en él, y notar que la diferencia que se generaba entre una media y otra eran muy parecidas y por lo tanto la detección siempre se inclinaba hacia un cierto tipo de fallas, nos daba todos los tipos de fallas o en su defecto, al tener una diferencia tan mínima entre una media y otra, la media total se conformaba de un determinado peso de todas las medias, dando como resultado una falla poco probable.

En la Fig. 19 se puede observar otro nodo intermedio denominado *"Auxiliar"*, con la única función de mostrar al usuario, el tipo de falla presentado en el nodo eléctrico. Igual que en el modelo anterior, el hecho de tener un nodo continuo más en el modelo, presentaba un problema con las varianzas. Por otra parte, la inserción de este nodo, no representaba una mejoría al sistema, así que simplemente se optó por eliminarlo.

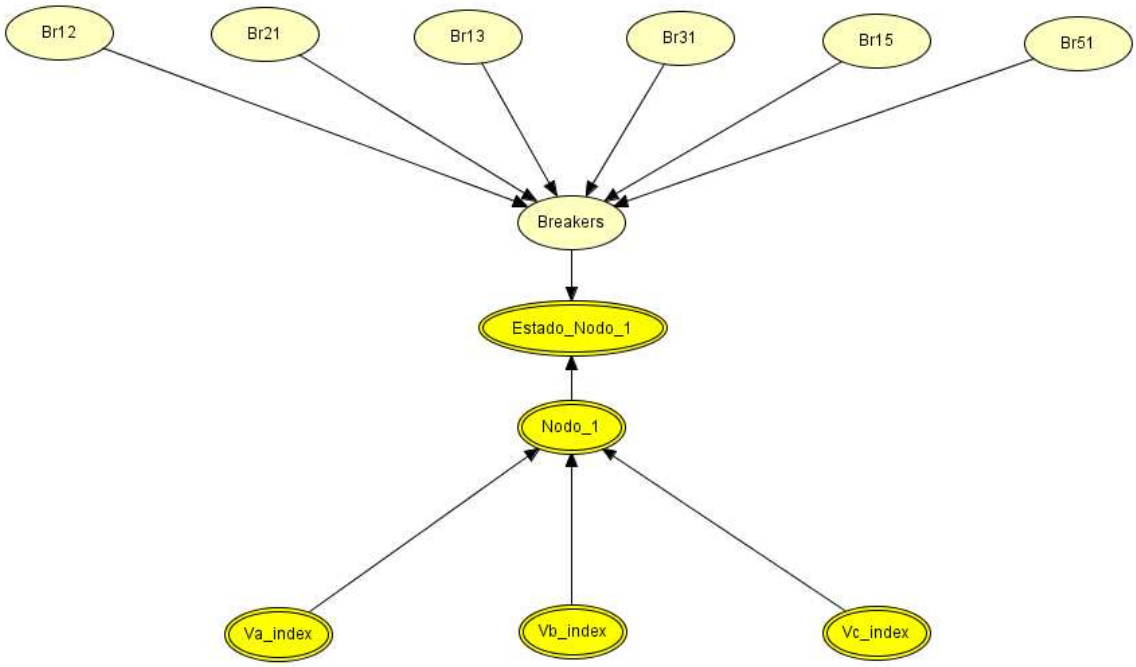

Figura 18: Estructura de RBH para la red eléctrica establecida

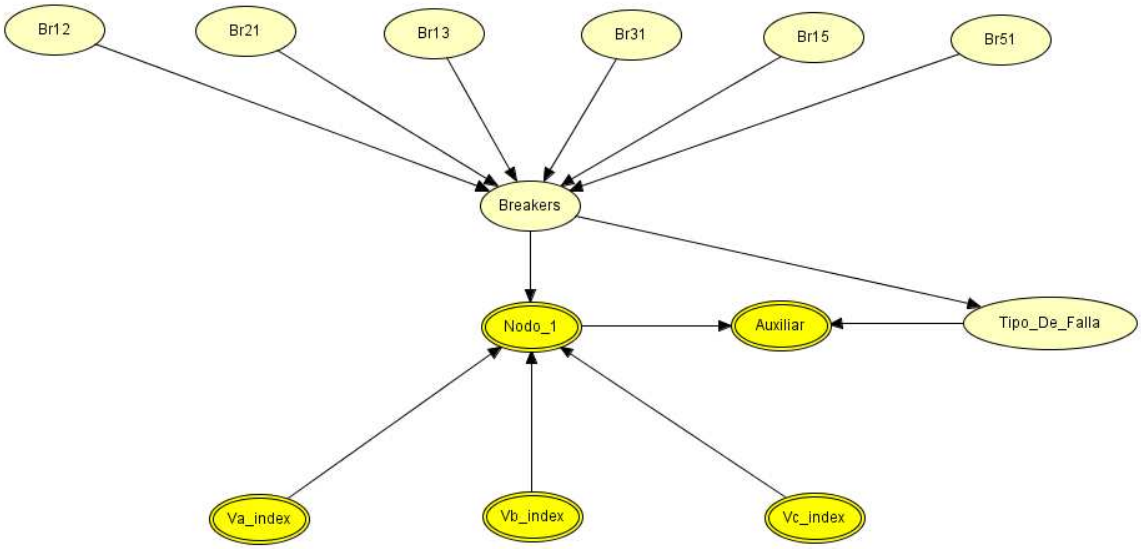

Figura 19: Estructura de RBH para la red eléctrica establecida

CAPÍTULO 4
Resultados

4.1 Sinopsis

Una vez que el modelo en pequeña escala funciona adecuadamente, se puede realizar la investigación a gran escala o visto de otra forma, su expansión a todos los nodos de la red. En la siguiente sección, se presenta el modelo completo de la red eléctrica estudiada con una pequeña descripción de los puntos más importantes. Las pruebas realizadas al modelo y los resultados obtenidos, son presentados en la sección 3. Y en la última sección, se compara la eficiencia obtenida o el grado de éxito obtenido de este modelo, con otro modelo que posee características similares.

4.2 Modelo de la red eléctrica completa

El octavo modelo aquí presentado, fue el único que obtuvo resultados positivos en el momento de realizarse pruebas con diferentes nodos por separado. Por lo que el siguiente paso fue elaborar el modelo para todos los nodos de la red, el cual se muestra la Fig. 20.

Dentro de los puntos importantes del diseño completo de la RBH para la red eléctrica establecida, se tienen:

- La relación que existen entre todos los nodos, son dadas por los *"Br's"*, los cuales en la red eléctrica establecida, se encuentra posicionadas entre un nodo y otro. (Ver Fig. 1).

- Las varianzas de cada nodo son diferentes, dependiendo del grado de daño que puedan sufrir por la presencia y/o ausencia de fallas en nodos cercanos. Por ejemplo, nodo 7-8, y nodos 9-10-11-12. (Ver Tabla 4).

- Existen nodos en los cuales aunque la varianza sea muy grande, no se pudo llegar a un estado *"Normal"* de operación cuando otro nodo continuo presenta algún tipo de falla (datos correlacionados), estos nodos tuvieron que ser declarados hijos también, de los nodos que les perjudicaban en sus medias, de manera que aunque los nodos continuos presenten fallas, estos puedan presentar el estado de modo normal. Ejemplos de estos nodos son: 7, 9, 10, entre otros.

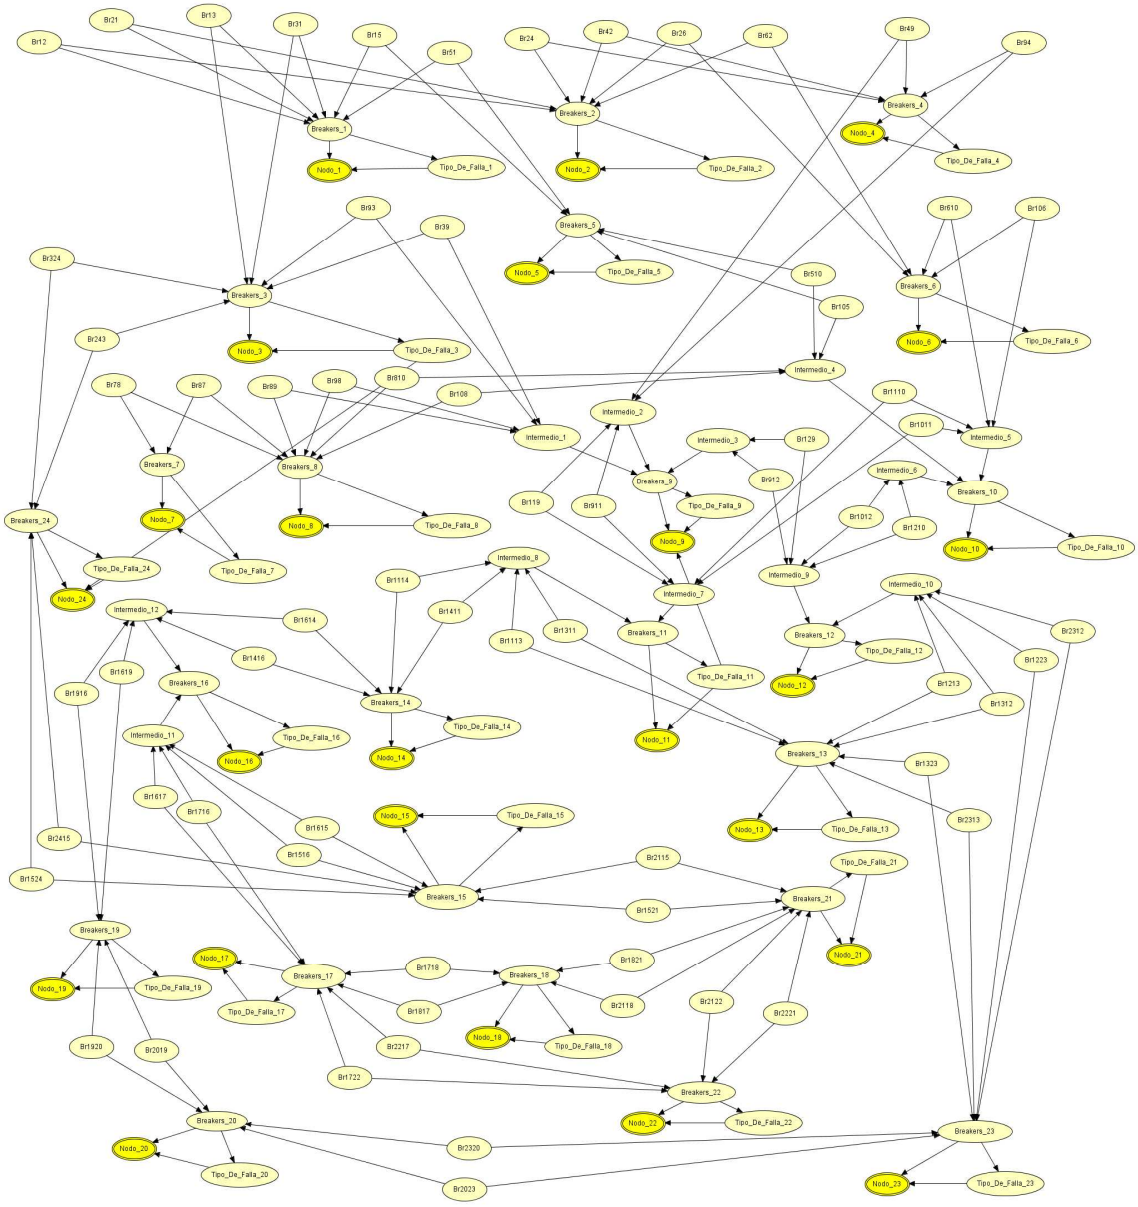

Figura 20: Estructura completa de RBH para la red eléctrica establecida

4.3 Pruebas y Resultados

Se realizaron 10 pruebas de fallas simples y simultáneas (de 2 a 5 fallas) para probar el modelo final; los nodos y las fallas presentadas fueron elegidos aleatoriamente y pueden ser del tipo línea-línea, una-dos y tres-fases a tierra (ver Apéndice D, tabla D.1). De estos

10 escenarios de falla, 5 fueron utilizados para el entrenamiento de la RBH y 5 fueron utilizados propiamente para la validación del modelo.

El porcentaje de resultados correctos obtenidos, se muestra en la Tabla 12.

No. Fallas	*%*
1 Falla	100
2 Fallas	70
3 Fallas	40
4 Fallas	55
5 Fallas	48

Tabla 12: Porcentaje de eficiencia del modelo propuesto

No. Fallas/ Tipo de Fallas	*1 Falla*		*2 Fallas*		*3 Fallas*		*4 Fallas*		*5 Fallas*		*%*
	Cor-recto	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	
A-B	1	0	2	0	0	3	0	2	1	2	36.36
A-C	1	0	1	0	0	0	0	1	2	2	57.14
B-C	0	0	1	0	0	3	1	0	3	1	55.56
A-Gnd	0	0	0	0	1	0	1	1	1	1	60.0
B-Gnd	0	0	0	0	0	1	1	1	0	0	33.33
C-Gnd	2	0	0	0	0	1	1	1	1	3	44.44
AB- Gnd	1	0	0	2	2	0	1	0	0	0	66.67
AC- Gnd	0	0	1	1	1	0	0	2	1	0	50.0
BC- Gnd	0	0	2	0	1	0	2	3	0	1	55.56
ABC- Gnd	0	0	0	0	1	1	2	0	4	2	70.0

Tabla 13: Porcentaje de eficiencia por tipo de falla

La Tabla 12 muestra la detección correcta de las fallas que se presentaron en casos particulares, hablando en una forma general se puede decir que de 75 escenarios de falla, sólo 40 de ellos fueron detectados correctamente (nodos con fallas) y 35 no pudieron ser identificados adecuadamente, dejando un porcentaje de éxito del 53.33%, solamente un poco por encima de la mitad de los escenarios planteados; sin embargo, es importante mencionar que todos los nodos en donde no se presentó falla, fueron diagnosticados correctamente, dato que no se ve reflejado en los datos previamente presentados.

Con la Tabla 13 simplemente se quiso mostrar a cuáles fallas es más sensible el modelo, así como a cuál es menos sensible. La falla más fácil de detectar por el modelo propuesto, es la correspondiente a 3 fases a tierra (A-B-C Gnd), mientras que la más difícil de detectar o la más erróneamente detectada es la falla B Gnd (una sola fase a tierra).

Como se puede observar, el porcentaje de eficiencia tiende a decrementarse conforme el número de fallas simultáneas es mayor y esto es debido al alto grado de interrelación que tienen los nodos entre sí, por lo que cada vez que se presenten más fallas, los índices de falla obtenidos de los voltajes de los nodos, se verán más afectados, haciendo de la tarea del diagnóstico de fallas, algo muy difícil. Se concluye, que se tiene que realizar una

extracción de rasgos característicos diferente de las señales, en donde no se vea reflejada la sensibilidad de la correlación que tienen los nodos entre sí y más la firma de cada señal o en su defecto, un modelo diferente de RBH.

4.4 Comparación con otras estrategias existentes

Para evaluar el grado de eficiencia en la detección y diagnóstico de fallas de los componentes con respecto a otros sistemas de dos etapas para el mismo propósito, se realizó una comparación entre el modelo final presentado hasta este momento, en este reporte y el sistema de identificación de Garza [2], basado en DICL (lógica de opción independiente dinámica) y DPMs (modelos probabilísticos dinámicos), específicamente en Redes Bayesianas Discretas y modelos probabilísticos de máxima entropía. Se realizaron 48 simulaciones, en la red eléctrica seleccionada, en donde aleatoriamente se seleccionaron un conjunto de 4 nodos de prueba (nodos 3, 9, 10 y 13) y se probaron ambos modelos para saber el estado real de éstos.

Las simulaciones fueron divididas para realizar dos tipos de pruebas. En la primera evaluación, cada simulación incluía uno de los cuatro nodos elegidos previamente para prueba con alguna falla aleatoria (línea a línea, una, dos o tres fases a tierra), y fallas aleatorias en otros nodos. La prueba de eficiencia, gira en torno a la determinación correcta del estado del nodo de prueba. La segunda evaluación consistió en la simulación de fallas aleatorias den los 4 nodos de prueba y la identificación correcta del estado de cada nodo. En ambas evaluaciones, el estado del interruptor de protección de seguridad fue determinado por la selección aleatoria de uno de sus tres estados: OPEN, FAIL, OK.

La primera evaluación incluye el conjunto de simulaciones mostrada en la tabla D.2, del Apéndice D. Se pudo determinar el modo de operación correcto para el nodo de prueba en 19 de 24 pruebas en el modelo aquí presentado, esto es un 79.16% de éxito, en comparación con 22 de 24 correctas determinaciones del estado de nodo de prueba para el modelo de Garza [2], es decir, 91.6% de eficiencia. El resumen de las estadísticas por tipo de falla y por nodo son mostradas en las tablas 14 y 15.

Como se puede observar en la Tabla 14, el modelo aquí propuesto mejora el porcentaje de eficiencia del modelo basado en DICL-DPM para la detección de cierto tipo de fallas. Sin embargo, el porcentaje de eficiencia en casi todos los demás tipos de fallas es menor. En cuanto a la Tabla 15, se puede observar que en general el porcentaje de eficiencia por nodo, es mayor en el modelo DICL-DPM. Las comparaciones realizadas pueden verse en las Fig. 21 y 22.

La segunda evaluación incluye las simulaciones mostradas en la tabla D.3, en el Apéndice D. El nivel de eficiencia es de 57.29%, con la determinación del estado correcto del nodo en 55 de los 96 casos de prueba; en comparación con un 87.5% de una correcta identificación en el modelo de Garza [2], siendo solo 12 los casos identificados erróneamente. Las estadísticas por tipo de falla y por nodo son mostradas en las Tablas 16 y 17.

	Modelo RBH			*Modelo DICL-DPM*		
Estado del nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
A-B-C Gnd	3	1	75.0	4	0	100.0
A-B Gnd	1	1	50.0	2	0	100.0
A Gnd	5	0	100.0	4	1	80.0
A-B	4	0	100.0	3	1	75.0
B-C	3	3	50.0	6	0	100.0
No Fault	3	0	100.0	3	0	100.0

Tabla 14: Evaluación 1 por tipo de falla

	Modelo RBH			*Modelo DICL-DPM*		
Número de nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
3	5	1	83.33	6	0	100.0
9	3	3	50.0	6	0	100.0
10	5	1	83.33	4	2	66.7
13	6	0	100.0	6	0	100.0

Tabla 15: Evaluación 1 por nodo

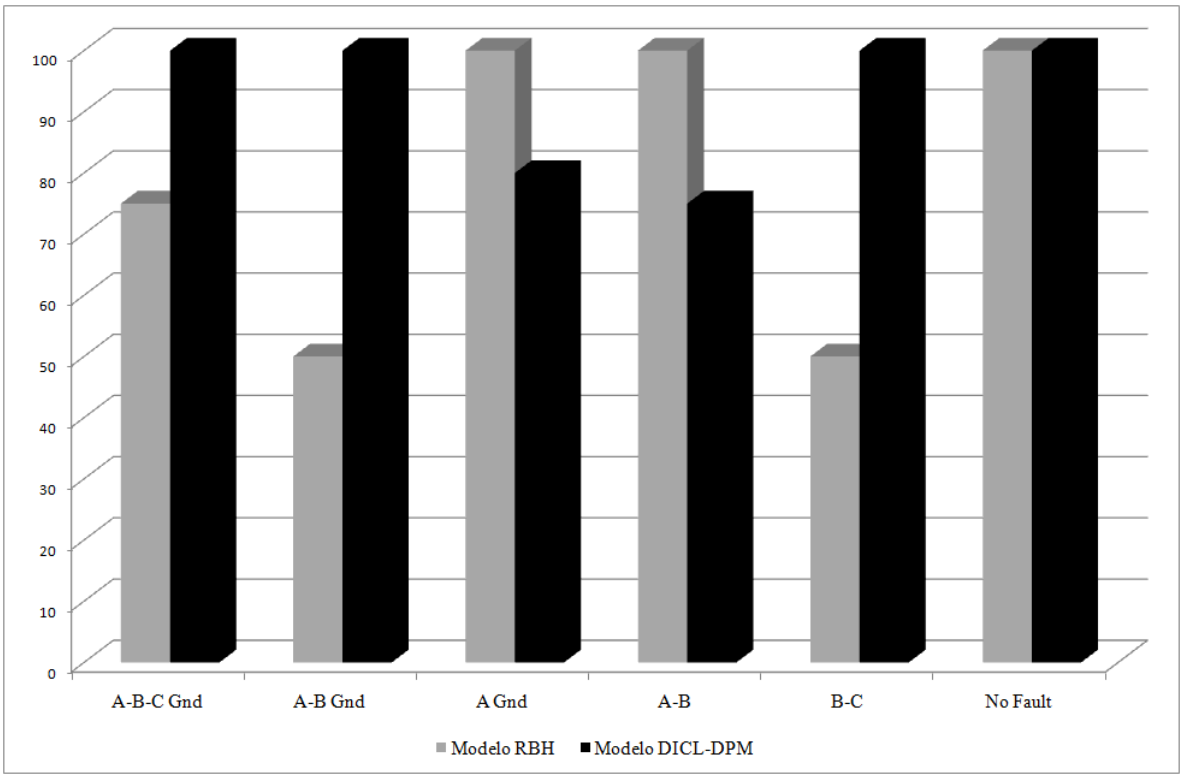

Figura 21: Gráfica de evaluación 1 por nodo

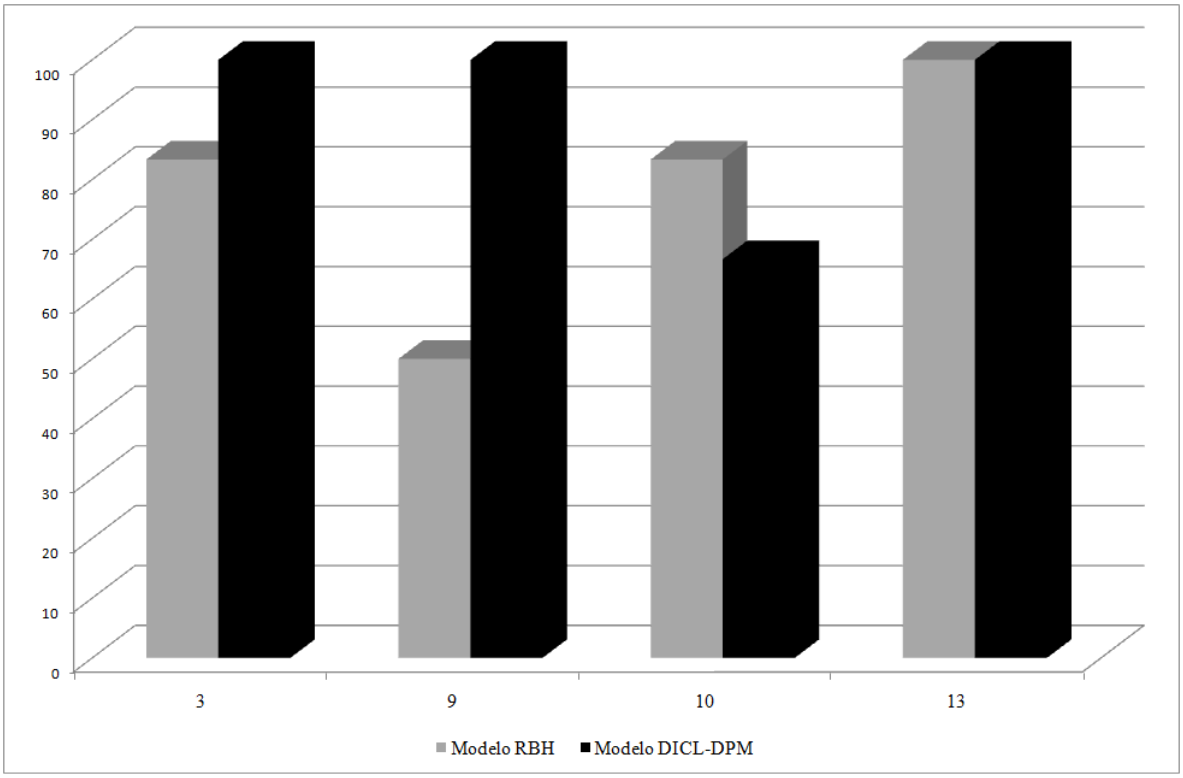

Figura 22: Gráfica de evaluación 1 por tipo de falla

	Modelo RBH			*Modelo DICL-DPM*		
Estado del nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
A-B-C Gnd	7	7	50.0	14	0	100.0
A-B Gnd	4	6	40.0	10	0	100.0
A Gnd	6	8	42.86	12	2	85.7
A-B	8	10	44.44	15	3	83.3
B-C	6	10	37.5	16	0	100.0
No Fault	24	0	100.0	17	7	70.8

Tabla 16: Evaluación 2 por tipo de falla

	Modelo RBH			*Modelo DICL-DPM*		
Número de nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
3	13	11	54.16	19	5	79.1
9	13	11	54.16	21	3	87.5
10	8	16	33.33	21	3	87.5
13	21	3	95.8	23	1	95.8

Tabla 17: Evaluación 2 por nodo

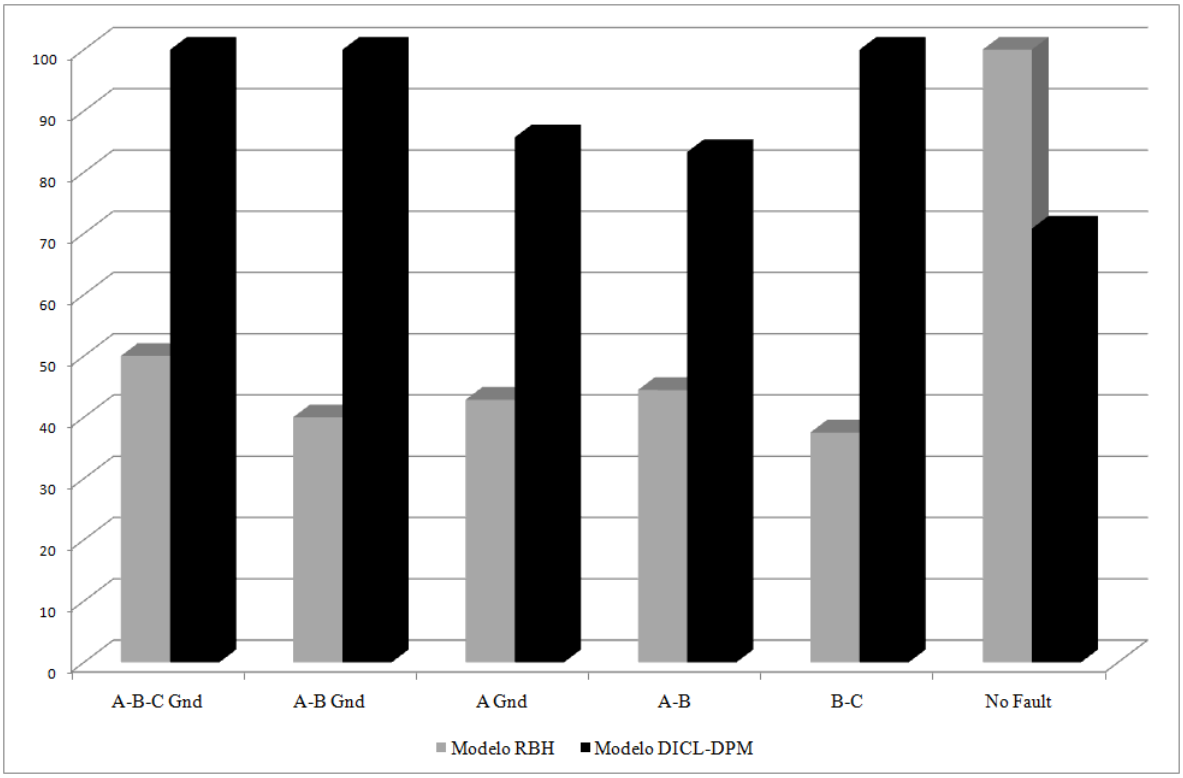

Figura 23: Gráfica de evaluación 2 por nodo

En la Tabla 14 se observa, que el tipo de error más común es la asignación de la falla cuando se tiene una falla línea a línea, en especial, las fases B-C (62.5% detecta erróneamente). Esto es debido, a que se presenta en el nodo 3 un comportamiento muy peculiar, al presentarse este tipo de falla (ver sección 3.2.2, Fig. 9), el cual afecta de una manera negativa la detección de la falla en los demás nodos. Al tener una falla línea a línea B-C en el nodo 3, el voltaje decae por el tiempo en que la carga de falla se presenta, pero al quitarse esta carga de falla, el voltaje no regresa a su nivel normal, por lo que afecta en el cálculo de medias, varianzas e índices de sí mismo, y de los demás nodos, es por esto, que es una falla que no permite el correcto diagnóstico la mayoría de las veces en otros nodos. En comparación con el modelo DICL-DPM, se puede observar que en general éste presenta mejores resultados, sin embargo, en el caso de nodos donde no existe falla, el modelo RBH presenta un mejor desempeño, acertando siempre el caso de falla o no falla. Las comparaciones realizadas pueden verse en las Fig. 23 y 24.

Por cada 24 nodos, solo 14 se pudieron detectar correctamente (esto es 57.29% de los casos) y no se pudieron identificar correctamente al menos los estados de 10 nodos. En comparación con el modelo DICL-DPM que obtuvo solo un nodo identificado erróneamente por cada 24 casos. En el modelo aquí presentado, solamente en 5 simulaciones se identificó correctamente el estado de los 4 nodos, teniendo un porcentaje de eficiencia de 20.83%, mientras que en el modelo DICL-DPM, se obtuvieron 13 simulaciones con un porcentaje de eficiencia de 54.2%. Esto es debido a que el modelo aquí propuesto, presenta resultados eficientes para la detección de 1 y 2 fallas, y resultados no tan prodigiosos para la detección de 3 fallas en adelante.

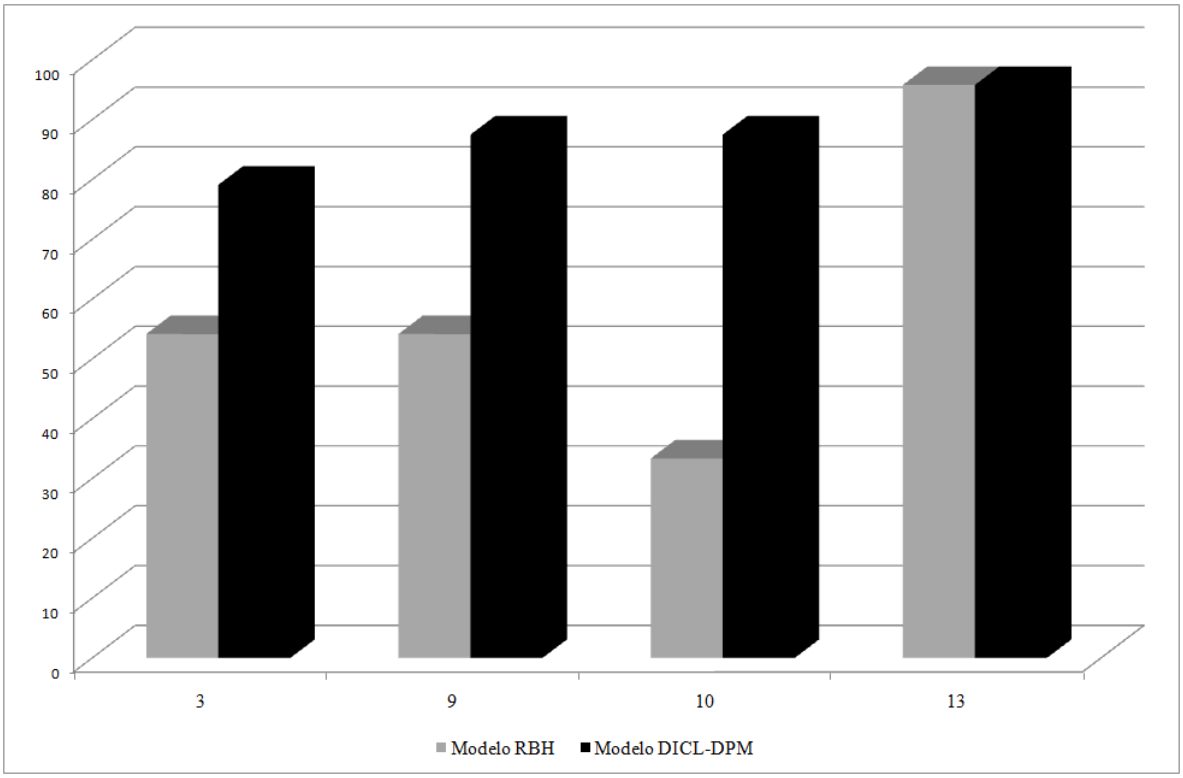

Figura 24: Gráfica de evaluación 2 por tipo de falla

CAPÍTULO 5: SEGUNDA PARTE
Optimización de enjambre de partículas (PSO)

5.1 Sinopsis

Una vez que el modelo ocho fue probado en su totalidad, nos dimos cuenta que los resultados obtenidos no eran los esperados y/o deseados. Por lo que se decidió mejorar el desempeño del algoritmo propuesto, mediante la optimización de los índices de estado obtenidos para cada nodo de la red eléctrica industrial. A continuación se hablará un poco, sobre el método de optimización.

En la segunda sección se presentará la información básica, para que la técnica PSO pueda ser comprendida por el lector. Una comparación con otras técnicas de cómputo avanzadas es realizada en la sección 3. La sección 4 presenta una pequeña introducción a las variantes que esta técnica tiene, y por último, el nuevo modelo y los resultados que éste arroja son presentados en la sección 5.

5.2 Optimización por Enjambre de Partículas (PSO)

De acuerdo con [68], PSO es una técnica de optimización robusta estocástica, basada en el movimiento y la inteligencia de los enjambres. Ésta aplica el concepto de la interacción social como solución a un problema. Desarrollada en 1995 por James Kennedy y Russell Eberhart, utiliza un número de agentes (partículas) que constituyen un enjambre moviéndose en un espacio de búsqueda tratando de encontrar la mejor solución. Cada partícula es tratada como un punto en un espacio N-dimensional, la cual ajusta su vuelo de acuerdo con su propia experiencia de vuelo así también como la experiencia de vuelo de otras partículas.

Cada partícula mantiene el rastro de sus coordinadas en el espacio de solución la cual está asociada con la mejor solución (adecuación) que ha logrado hasta el momento dicha partícula. Este valor es el denominado mejor valor personal: **pbest**.

Otro valor importante que es rastreado por el PSO es el mejor valor obtenido hasta el momento por cualquier partícula en el vecindario de esa partícula. Este valor es denominado: **gbest**.

El concepto básico de PSO recae en el aceleración de cada partícula en torno a la localización de los valores *pbest* y *gbest*, con una aceleración de peso aleatorio en cada paso de tiempo como se muestra en la Fig. 26.

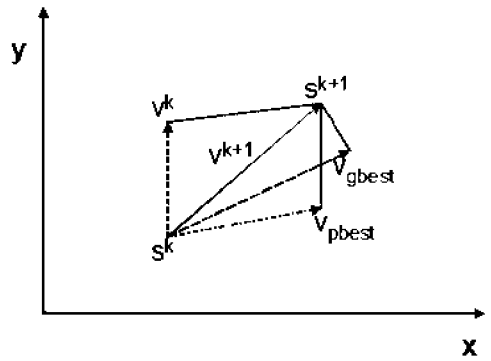

Figura 25: Concepto de la modificación de búsqueda de punto por PSO

En donde S^k es el punto de búsqueda actual, S^{k+1} es el punto de búsqueda modificado, V^k es la velocidad actual, V^{k+1} es la velocidad modificada, V_{pbest} es la velocidad basada en *pbest* y V_{gbest} es la velocidad basada en *gbest*.

Cada partícula intenta modificar su posición utilizando la siguiente información:

- Posiciones actuales,
- Velocidades actuales,
- Distancia entre la posición actual y pbest,
- Distancia entre la posición actual y gbest.

La modificación de la posición de la partícula puede ser modelada matemáticamente de acuerdo a la siguiente ecuación:

$$V_i^{k+1} = \omega V_i^k + c_1 rand_1(\cdots) x\left(pbest_i - S_i^k\right) + c_2 rand_2(\cdots) x\left(gbest - S_i^k\right) \tag{22}$$

donde:

V_i^k: velocidad del agente i en la iteración k,
ω: función de peso,
c_j: factor de peso,
rand: número aleatorio distribuido uniformemente entre 0 y 1,
S_i^k: posición actual del agente i en la iteración k,
$pbest_i$: pbest del agente i,
$gbest_i$: gbest del grupo (de todo el vecindario de las partículas).

La siguiente función de peso es usualmente utilizada en ecuación 22:

$$\omega = \omega Max - \frac{[(\omega Max - \omega Min) \times iter]}{maxIter} \tag{23}$$

donde:

wMax = peso inicial,
wMin = peso final,
maxIter = número máximo de iteraciones,
iter = número actual de iteración.

$$S_i^{k+1} = S_i^k + V_i^{k+1} \tag{24}$$

Para dejar en claro cómo funciona y qué es el valor de inercia (*w*), podemos decir que un valor alto facilita la búsqueda global, mientras que un valor pequeño facilita una búsqueda local. Decrementando linealmente el peso de inercia de un valor relativamente grande a un valor pequeño a través del curso de la corrida del algoritmo de PSO, arroja un mejor desempeño del PSO comparado con uno en donde en la configuración, los valores de inercia son estáticos.

En la Fig. 26 se muestra un diagrama de flujo del algoritmo PSO general.

5.3 Comparación con otras técnicas de computación evolucionadas

- A diferencia de los algoritmos genéticos, estrategias y programación evolucionarias, en PSO, no hay una operación de selección.
- Todas las partículas en PSO son mantenidas como miembros de la población a través del curso de la corrida.
- PSO es el único algoritmo que no implementa la sobrevivencia del más adecuado.
- No hay operación de cruce en PSO.
- En el balance EP (expectativa de propagación), la búsqueda local y global puede ser ajustado a través de la estrategia de parámetros, mientras que en PSO el balance es logrado mediante el factor inercial de peso de la ecuación 22.

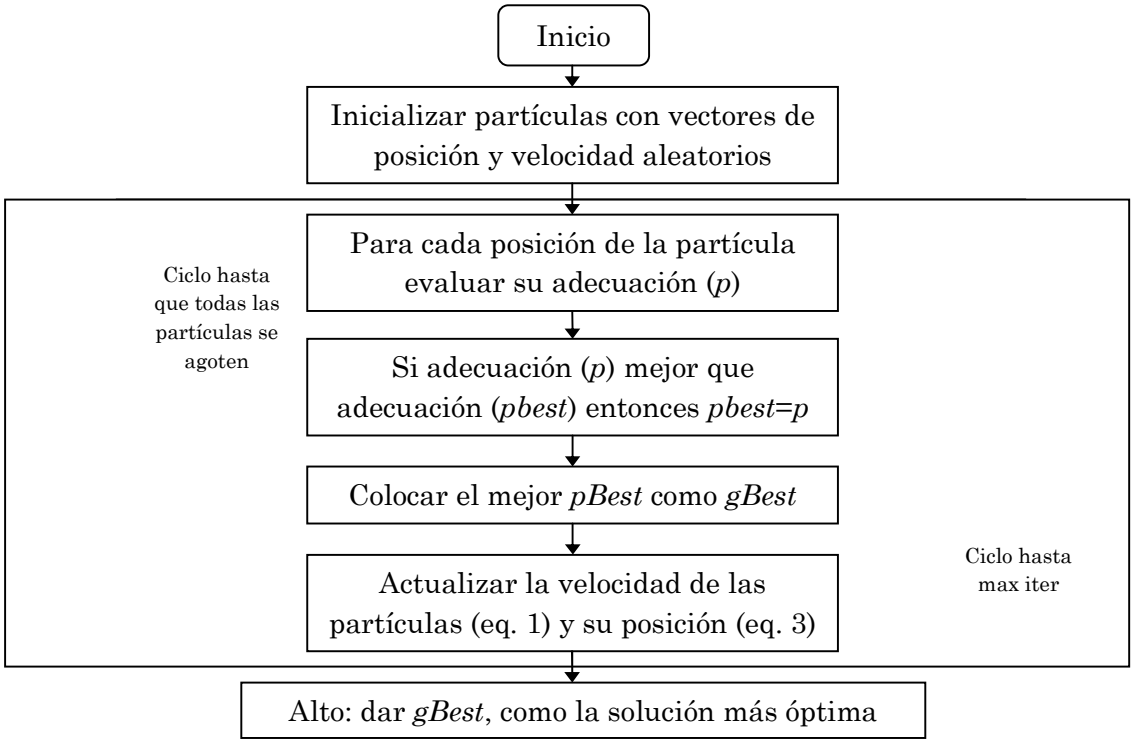

Figura 26: Diagrama de flujo de algoritmo PSO

5.4 Variantes del PSO

- PSO discreto: puede manejar variables con valores discretos binarios
- MINLP PSO: puede manejar variables binarias discretas y continuas
- PSO Híbrido: Utiliza el mecanismo básico del PSO y la selección natural del mecanismo, el cual es usualmente utilizado por métodos Evolutivos como los son los GAs (algoritmos genéticos).

5.5 Noveno Modelo: Descripción

Como se mencionó anteriormente, los resultados obtenidos del octavo modelo aquí presentado en la sección 3.3.14, no fueron los que se tenían contemplados, debido a que su porcentaje de eficiencia general en algunas pruebas, fue ligeramente superior a la mitad de

escenarios de falla totales establecidos para la validación del modelo. Por lo que se intentó en primera instancia, optimizar los índices de falla, mediante una mejora en los coeficientes que dan peso a cada fase *da, db* y *dc*, y que son utilizados en la ecuación 21, para el cálculo de estos índices.

El noveno modelo, básicamente va a consistir de la misma estructura del modelo ocho presentado anteriormente, pero con índices de falla optimizados. El acondicionamiento de los datos, es realizado mediante la técnica de optimización PSO, misma que ya fue explicada en las secciones anteriores. Se realizó un código en Matlab (ver Apéndice E), en donde se buscaban los valores *da, db* y *dc* (optimización de los pesos en los índices) para cada determinado nodo, haciendo que éstos estén lo más separados posibles uno del otro, para mejorar el proceso de detección e identificación de fallas con la red bayesiana. La Tabla 18 muestra los valores finales de los pesos calculados para cada nodo.

# Nodo	*da*	*db*	*dc*
1	0.92438352	-1.0938529	-0.39598603
2	0.94512342	-1.0883816	-0.4481636
3	-1.1346494	0.86331286	-0.43487641
4	0.86867458	-0.9561698	-0.552370387
5	0.98538248	-1.1310038	-0.371219201
6	-0.3294367	0.9127531	-0.565408643
7	0.97374139	-1.0246009	-0.614966914
8	0.95179529	-0.8207409	-0.524871111
9	0.89106819	-1.0806503	-0.447046473
10	0.99236772	-1.1818422	-0.391478543
11	0.95638247	-0.642566	-0.547048683
12	0.7620441	-1.2469102	-0.060415861
13	-1.140359	0.8565737	0.158415697
14	0.98612291	-0.9331335	-0.547074455
15	0.90156923	-1.0409642	-0.405053685
16	-1.0736157	0.80313698	0.256051405
17	0.95936484	-0.8038717	-0.500919737
18	-1.0967336	0.88434179	-0.002767367
19	0.96717431	-0.5457023	-0.592630335
20	0.96081189	-0.6262053	-0.57887551
21	0.95644288	-0.870513	-0.501371015
22	-1.2668918	1.00209647	-0.334834665
23	0.92819205	-1.014294	-0.30871549
24	0.83303935	-0.9617481	-0.535335312

Tabla 18: Pesos para calcular índice de fallas obtenidos con PSO

Los valores de los pesos de cada fase para elaborar el índice de estado de cada nodo, se compone del valor enlistado en la Tabla 18 multiplicado por un factor de 1×10^3. Los valores de los nuevos índices de falla pueden ser localizados en la tabla C.2, del Apéndice C.

5.6 Pruebas y Resultados

Al comparar los índices de falla optimizados y sin optimizar (tablas C.1 y C.2, del Apéndice C), se puede observar que aunque es cierto que muchos de estos índices ahora presentan mayor diferencia uno entre otro, existen algunos índices entre una falla y otra que no presentan gran variación, es decir, aunque los valores de los pesos se hayan optimizado, eso no logra desaparecer de una manera significativa la interrelación entre los nodos que se ve reflejada en los índices de falla. Por lo que se decide, realizar un solo tipo de evaluación para observar si la eficiencia del modelo, se incrementa significativamente. Los escenarios de falla escogidos aleatoriamente, son los de la evaluación 2 de la tabla D.3, del Apéndice D.

Los resultados de dicha evaluación, se muestran en las Tablas 17 y 18.

Como se puede observar en las Tablas 19 y 20, existe una mejoría en el número de fallas incorrectamente leídas en los nodos de prueba, decrementándose de 41 a 38 errores, esto daría un porcentaje de eficiencia del 60.42%. El nuevo modelo con respecto al anterior en cuanto al tipo de falla detectada se refiere, decrementa su porcentaje de eficiencia de 50 a 28.57% en fallas de tipo 3 fases a tierra. Sin embargo, mejora en un 33.34% en la detección de fallas de tipo línea a línea. En cuanto a los demás tipos de estados que se presentan en los nodos de prueba, los resultados son los mismos.

En cuanto a la Tabla 20, se observa una mejoría de la mayoría de los nodos de prueba, siendo solo el nodo 13 el único cuya eficiencia se decrementa, sin embargo, aún con este decremento, su porcentaje de eficiencia sigue siendo aceptable. Para una mejor visualización, la comparación entre el modelo RBH anterior y el modelo RBH con PSO, se muestra en las Figs. 27 y 28.

Haciendo una comparación entre los resultados de ambos modelos, con y sin optimización de índices de fallas, se concluye que aunque la eficiencia mejoró, el cambio no es muy notable, por lo tanto no se realizan las demás evaluaciones faltantes. Aunque la eficiencia es aceptable, aún no se habían alcanzado los resultados esperados; por lo que se desiste en el intento de optimización de parámetros y se busca una nueva forma de mejorar el modelo.

	Modelo RBH			*Modelo RBH (Pesos diferentes)*		
Estado del nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
A-B-C Gnd	7	7	50.0	4	10	28.57
A-B Gnd	4	6	40.0	4	6	40
A Gnd	6	8	42.86	6	8	42.86
A-B	8	10	44.44	14	4	77.78
B-C	6	10	37.5	6	10	37.5
No Fault	24	0	100	24	0	100

Tabla 19: Comparación de evaluación 2 por tipo de falla

	Modelo RBH			*Modelo RBH (Pesos diferentes)*		
Número de nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
3	13	11	54.16	13	11	54.16
9	13	11	54.16	14	10	58.33
10	8	16	33.33	11	13	45.83
13	21	3	95.8	20	4	83.33

Tabla 20: Comparación de evaluación 2 por nodo

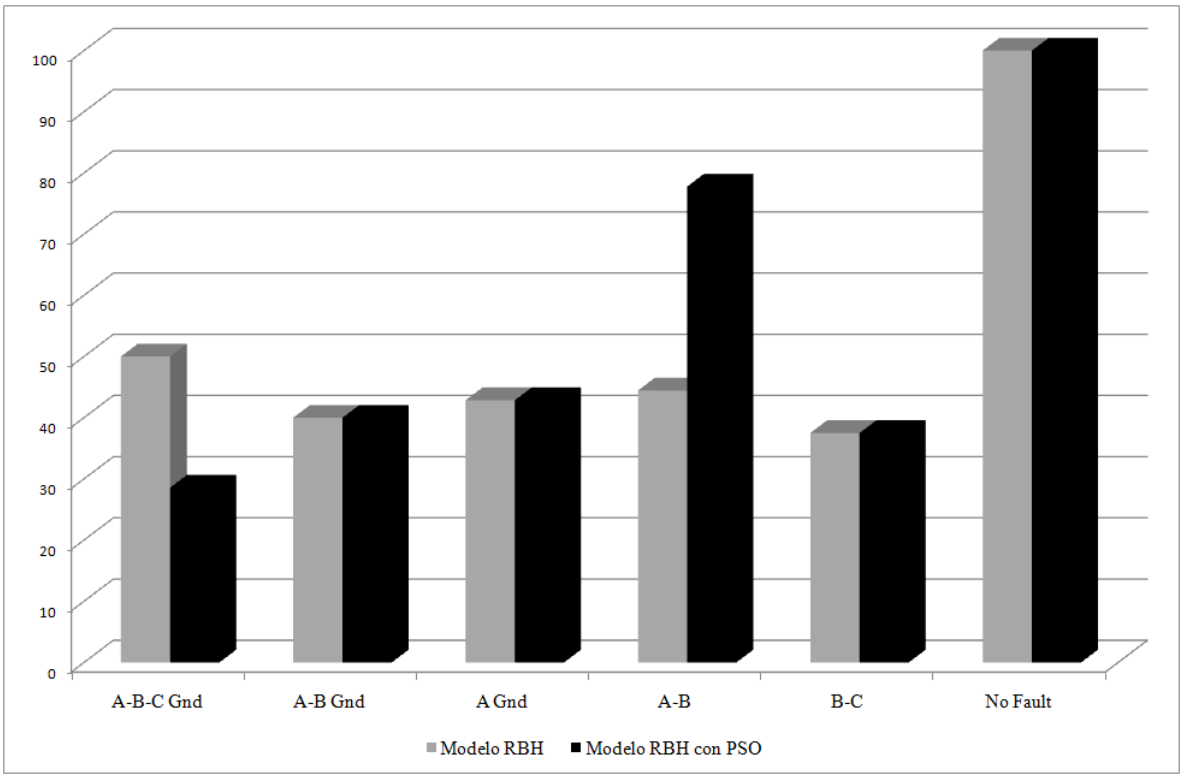

Figura 27: Gráfica de evaluación 2 por tipo de falla

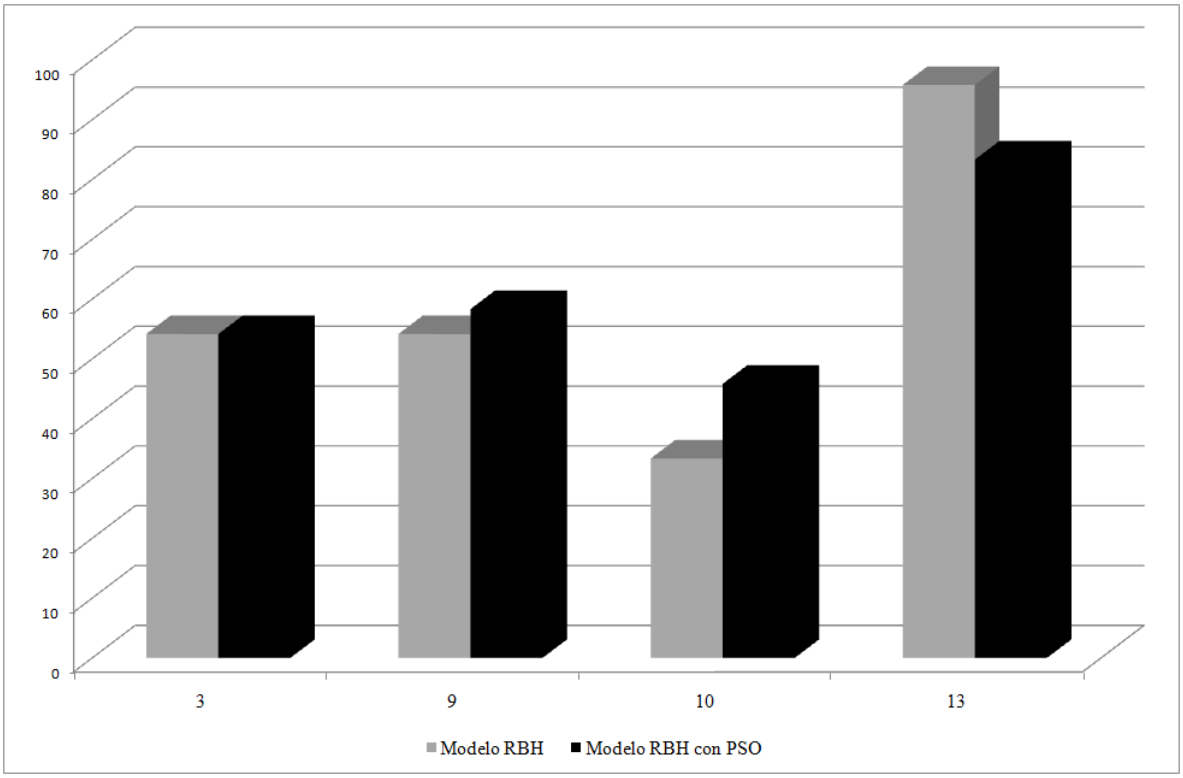

Figura 28: Gráfica de evaluación 2 por nodo

CAPÍTULO 6: TERCERA PARTE
Análisis de datos: Teoría de onduletas (Wavelets)

6.1 Sinopsis

En capítulos anteriores se estudió la manera de realizar diversas estructuras de Redes Bayesianas Híbridas, mediante la inserción de datos discretos provenientes de las lecturas de los interruptores de protección y datos continuos de los voltajes trifásicos obtenidos de los nodos de la red eléctrica estudiada. Sin embargo, los resultados no fueron los esperados, por lo que al determinar las causas de los porcentajes tan bajos de eficiencia obtenidos en las pruebas, se determinó que la problemática radicaba en la extracción de rasgos característicos y formulación de índices de los datos continuos, por lo tanto se deberían buscar y utilizar otras técnicas que arrojaran mejores resultados.

Entre las técnicas investigadas, la que más se destacó por su uso en problemáticas parecidas a la aquí descrita [69], [70], [71], [72] y su simpleza de implementación, fue la teoría de onduletas (wavelets). Si bien, esta es una teoría no tan antigua (15 años desde su descubrimiento), es un tema interesante y de grandes aplicaciones. En este capítulo se presentará, un pequeño resumen de los fundamentos de esta teoría. En la primera sección se establecerán las diferencias entre una Transformada de Fourier y las Onduletas. La Ondeleta Continua será brevemente vista en la segunda sección, junto con algunas de las propiedades que éstas deben presentar. En la tercera sección, se hablará de las Onduletas discretas, las cuáles son realmente el punto principal de éste capítulo, debido a su uso en la resolución de nuestra problemática. La transformada de Onduletas discretas será vista en la cuarta sección, y en nuestra última sección, se analizarán los datos obtenidos en nuestro propio ejemplo.

6.2 Transformada de Fourier vs. Ondeletas

La transformada de Fourier (FFT) es una técnica matemática que nos permite representar una señal, como una suma de senos y cosenos, posiblemente infinita, es decir, expresa una señal en base temporal a una en base a frecuencias. La forma en que esto se realiza, se describe en la siguiente fórmula:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \tag{25}$$

La ecuación 25, puede ser interpretada de la siguiente manera, la señal *f(t)* será multiplicada por un término exponencial, elevado a una cierta frecuencia ω y después

CAPÍTULO 6: TERCERA PARTE
Análisis de datos: Teoría de onduletas (Wavelets)

6.1 Sinopsis

En capítulos anteriores se estudió la manera de realizar diversas estructuras de Redes Bayesianas Híbridas, mediante la inserción de datos discretos provenientes de las lecturas de los interruptores de protección y datos continuos de los voltajes trifásicos obtenidos de los nodos de la red eléctrica estudiada. Sin embargo, los resultados no fueron los esperados, por lo que al determinar las causas de los porcentajes tan bajos de eficiencia obtenidos en las pruebas, se determinó que la problemática radicaba en la extracción de rasgos característicos y formulación de índices de los datos continuos, por lo tanto se deberían buscar y utilizar otras técnicas que arrojaran mejores resultados.

Entre las técnicas investigadas, la que más se destacó por su uso en problemáticas parecidas a la aquí descrita [69], [70], [71], [72] y su simpleza de implementación, fue la teoría de onduletas (wavelets). Si bien, esta es una teoría no tan antigua (15 años desde su descubrimiento), es un tema interesante y de grandes aplicaciones. En este capítulo se presentará, un pequeño resumen de los fundamentos de esta teoría. En la primera sección se establecerán las diferencias entre una Transformada de Fourier y las Onduletas. La Ondeleta Continua será brevemente vista en la segunda sección, junto con algunas de las propiedades que éstas deben presentar. En la tercera sección, se hablará de las Onduletas discretas, las cuáles son realmente el punto principal de éste capítulo, debido a su uso en la resolución de nuestra problemática. La transformada de Onduletas discretas será vista en la cuarta sección, y en nuestra última sección, se analizarán los datos obtenidos en nuestro propio ejemplo.

6.2 Transformada de Fourier vs. Ondeletas

La transformada de Fourier (FFT) es una técnica matemática que nos permite representar una señal, como una suma de senos y cosenos, posiblemente infinita, es decir, expresa una señal en base temporal a una en base a frecuencias. La forma en que esto se realiza, se describe en la siguiente fórmula:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \tag{25}$$

La ecuación 25, puede ser interpretada de la siguiente manera, la señal *f(t)* será multiplicada por un término exponencial, elevado a una cierta frecuencia ω y después

integrada en todo el tiempo. Es decir, la expansión de Fourier nos va a transformar la señal original al dominio de la frecuencia, por lo que tendrá una única resolución en frecuencias y no en tiempo. La información temporal se pierde y por lo tanto no es posible establecer en qué período de tiempo de la señal se dio determinada frecuencia, mostrando así su principal desventaja. Un ejemplo de la transformada de Fourier se observa en la Fig. 29.

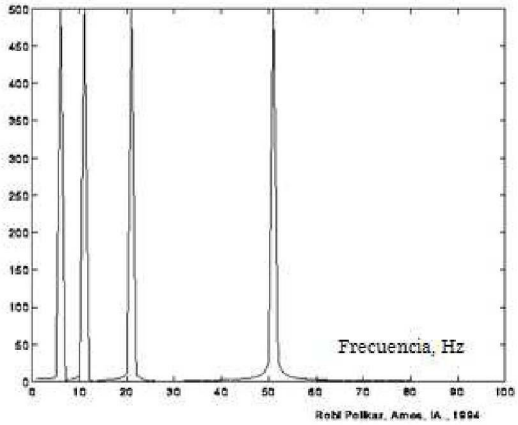

Figura 29: Transforma de Fourier de la función
*x(t)=cos(2*π*5*t)+cos(2*π*10*t)+cos(2*π*20*t)+cos(2*π*50*t)*

La transformada de Fourier como puede observarse, es una técnica importante para el estudio de señales estacionarias, sin embargo, si la señal es no-estacionaria, como lo son en las problemáticas relacionadas con la detección de fallas, la técnica no es útil, debido a que no se puede aislar el período de tiempo en el cual ha sucedido un cambio en nuestra señal. Es por esta razón, que a lo largo de los años se buscó una manera de solucionar esta desventaja, para lo cual se plantearon diferentes técnicas.

El principio de incertidumbre de Heisenberg [73], establece que en términos de procesamiento de señales, el momento y la posición de una partícula en movimiento no pueden ser conocidas simultáneamente, es decir, no se puede saber en qué instante una frecuencia exacta, apareció en cierta señal. Por lo que, estaba claro que la metodología a utilizarse ahora, se basaría en ventanas móviles para el análisis de frecuencias en ciertos períodos de tiempo. Entre las técnicas desarrolladas, se pueden mencionar: la transformada de Fourier de corto término (STFT; uso de ventanas de análisis con valores fijos) y la teoría de las onduletas (wavelets; uso de ventanas móviles escaladas), siendo ésta última, la más actual y la utilizada para nuestro estudio. Ver Fig. 30.

La transformada de las onduletas o el análisis de las onduletas, utiliza una ventana modulada completamente escalable que resuelve el problema de tener ventanas de tamaño fijo. La ventana se mueve a lo largo de toda la señal y para cada posición el espectro de frecuencias es calculado, y este proceso es repetido varias veces con ventanas ligeramente más grandes (o más pequeñas) para cada nuevo ciclo [73]. De ésta manera se tendrán varias representaciones de tiempo-frecuencia (denominadas representaciones tiempo-escala en wavelets) de la señal original, con diferentes resoluciones.

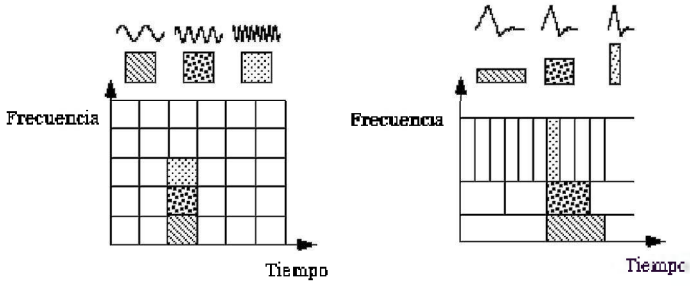

Figura 30: STFT vs. Onduletas [74]

Se puede observar en la Fig. 30 que la ventaja más grande que tiene la teoría de las onduletas, es que la ventana varía, de manera que si se quieren aislar discontinuidades en una señal, se pueden realizar un análisis con base en escalas muy pequeñas y si se requiere obtener un análisis de frecuencia, se pueden generar ventanas con muy altas escalas. Esto quiere decir, que a altas escalas se tiene una imagen general de la señal (mucha información y poca frecuencia) y a bajas escalas se muestran los detalles (información que necesita altas frecuencias).

Entre otras ventajas de las onduletas, en [75] se muestran las siguientes:

- Ésta teoría fue diseñada para el estudio de señales no estacionarias.
- Presenta covarianza ante retrasos, por lo que parece ser una herramienta muy útil en el estudio de señales con espectro de ley de potencia.
- Es un análisis tiempo frecuencia.
- Es capaz de revelar aspectos de los datos como tendencias, puntos de quiebre, discontinuidades en las derivadas, y auto-similaridad.
- El análisis de onduletas, puede muchas veces comprimir o eliminar ruido sin degradación apreciable.

6.3 La Transformada de la Onduleta Continua

La Onduleta Continua se define de la siguiente manera:

$$\gamma(s,\tau) = \int f(t)\Psi^*_{s,\tau}(t)dt \tag{26}$$

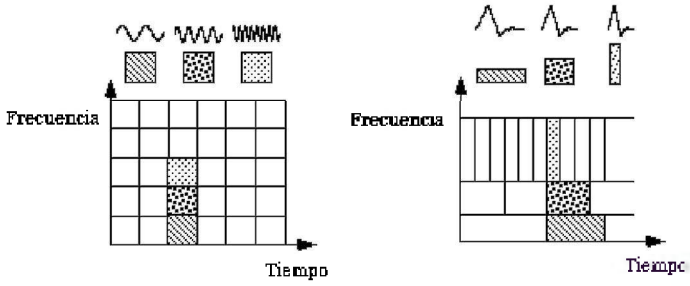

Figura 30: STFT vs. Onduletas [74]

Se puede observar en la Fig. 30 que la ventaja más grande que tiene la teoría de las onduletas, es que la ventana varía, de manera que si se quieren aislar discontinuidades en una señal, se pueden realizar un análisis con base en escalas muy pequeñas y si se requiere obtener un análisis de frecuencia, se pueden generar ventanas con muy altas escalas. Esto quiere decir, que a altas escalas se tiene una imagen general de la señal (mucha información y poca frecuencia) y a bajas escalas se muestran los detalles (información que necesita altas frecuencias).

Entre otras ventajas de las onduletas, en [75] se muestran las siguientes:

- Ésta teoría fue diseñada para el estudio de señales no estacionarias.
- Presenta covarianza ante retrasos, por lo que parece ser una herramienta muy útil en el estudio de señales con espectro de ley de potencia.
- Es un análisis tiempo frecuencia.
- Es capaz de revelar aspectos de los datos como tendencias, puntos de quiebre, discontinuidades en las derivadas, y auto-similaridad.
- El análisis de onduletas, puede muchas veces comprimir o eliminar ruido sin degradación apreciable.

6.3 La Transformada de la Onduleta Continua

La Onduleta Continua se define de la siguiente manera:

$$\gamma(s,\tau) = \int f(t)\Psi^*_{s,\tau}(t)dt \tag{26}$$

donde * denota una conjugación compleja. En la ecuación 26 se puede observar cómo es que la función f(t) es descompuesta en una serie de funciones base $\Psi^*_{s,\tau}$, denominadas onduletas [73]. La señal transformada es una función de dos variables, τ y s, que corresponden a los parámetros de traslación y escala, respectivamente.

Las onduletas están formadas a partir de una única función transformante $\Psi(t)$, denominada *onduleta madre*, a continuación se muestra la fórmula que la describe:

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}}\Psi\left(\frac{t-\tau}{s}\right) \tag{27}$$

De la ecuación 27, se puede observar cómo es que la onduleta madre es variada dependiendo de los dos parámetros ya mencionados, τ y s, y el factor $s^{-1/2}$ se refiere a la normalización de la energía a través de diferentes escalas. Si hacemos una combinación de las fórmulas 26 y 27, la ecuación de la onduleta continua nos queda de la siguiente manera [76]:

$$CWT^{\psi}_{\chi}(\tau,s) = \Psi^{\psi}_{\chi}(\tau,s) = \frac{1}{\sqrt{|s|}}\int f(t)\psi^*\left(\frac{t-\tau}{s}\right)dt \tag{28}$$

Se debe notar que las funciones bases de las onduletas no están especificados, debido a que la teoría de la transformada de onduletas define un espacio de trabajo en donde cada quien puede diseñar sus propias onduletas conforme sus propios deseos.

El nombre de onduleta madre, fue dado debido a dos importantes propiedades que a continuación serán mencionadas.

La primera propiedad de la onduleta madre, es la denominada condición de admisibilidad [77] (ecuación 29), con la cual, ésta puede ser utilizada primero para analizar y después reconstruir la señal sin pérdida de información, en donde, en términos cortos, se establece que la $\Psi(t)$ debe ser oscilatoria o más bien, una onda. El término onduleta significa *onda pequeña*, refiriéndose a la condición de que la función es de tamaño finito [76]. Esto se puede observar, debido a que la condición de admisibilidad implica que la transformada de Fourier de $\Psi(t)$ (ecuación 30), debe de desvanecerse en la frecuencia cero, esto es, un valor de cero en la frecuencia cero significa que el valor promedio de la onduleta en el dominio del tiempo debe ser cero (ecuación 31), y por lo tanto oscilatoria [73]. El término madre implica que esta onduleta es un prototipo para generar las otras funciones de las ventanas móviles.

$$\int \frac{|\Psi(\omega)|^2}{|\omega|}d\omega < +\infty \tag{29}$$

$$|\Psi(\omega)|^2|_{\omega=0} = 0 \tag{30}$$

$$\int \Psi(t)dt = 0 \tag{31}$$

La segunda propiedad es la condición de regularidad, la cual establece que la función de onduleta debe tener algo de suavidad y concentración en ambos dominios: tiempo y frecuencia, al momento de decrementarse, conforme la escala se decremente [73]. En otras

palabras, el ancho y el largo de las ventanas móviles variarán según se especifique, pero el área de esta será constante. Esto es, que cada ventana representará una misma porción en el plano de tiempo-frecuencia, pero dadas diferentes proporciones al tiempo y la frecuencia. Ver Fig. 30.

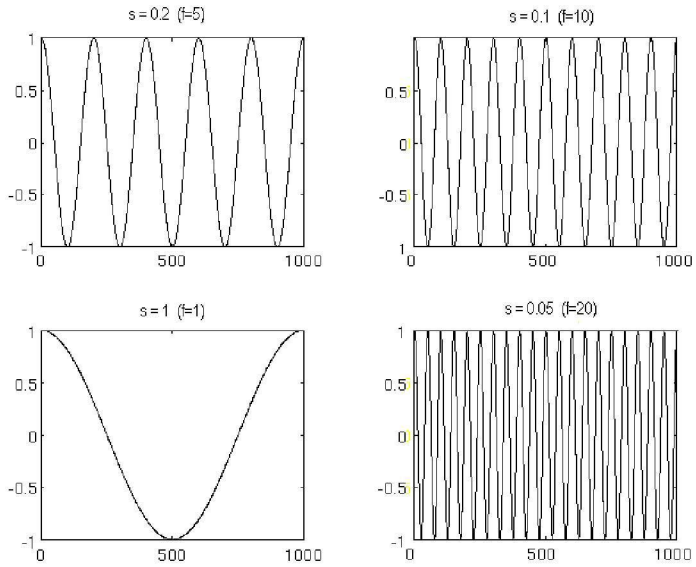

Figura 31: Señal coseno a diferentes escalas

El término traslación, está relacionado con la posición del ventanal durante la acción del movimiento de esta a través de la señal. En las onduletas, como ya se mencionó anteriormente, no se habla de un parámetro en base a la frecuencia, sino más bien en base a la escala, la cual se define como [76]:

$$s = \frac{1}{frecuencia} \tag{32}$$

Para tener una imagen de cómo se trabaja en base a escalas, observemos las ecuaciones 27 y 28. El parámetro s viene descrito en el denominador, por lo que mientras más grande sea la escala habrá una visión global y no detallada de la señal; en términos de frecuencia, esto sería tomado como bajas frecuencias que nos darían una información general de la señal. Mientras que si se tienen pequeñas escalas, estaríamos obteniendo una información detallada, correspondiente a altas frecuencias de la señal. Es así que podemos decir, que si $s>1$, la señal está comprimida y si $s<1$, la señal se encuentra dilatada o expandida (ver Fig. 31) [76].

6.4 Onduletas Discretas

En [73], se destacan 3 principales desventajas de las onduletas continuas, las cuáles son:

- Los coeficientes de onduletas son altamente redundantes y las funciones escaladas no estarán cerca de una base ortogonal. Esto debido a que la transformada de onduletas es calculada por el continuo movimiento de una función continuamente escalable sobre una señal y el cálculo de la correlación entre las dos.

- Se tiene un número infinito de onduletas en la transformada de onduletas. Sería más práctico reducir este número a uno más manejable.

- El último problema es que la mayoría de las funciones de las transformadas de onduletas no tienen soluciones analíticas y pueden ser solamente calculados numéricamente o por una computadora óptica análoga.

Una solución a los problemas antes mencionados fue la creación de la *Onduleta Discreta*. Las onduletas discretas no son continuamente escalables y trasladables, sino más bien, solamente pueden ser escaladas y trasladables en pasos discretos [73]. La ecuación para estas onduletas se obtiene modificando la ecuación 27 y queda de la siguiente manera [78]:

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{s_0^j}}\Psi\left(\frac{t-k\tau_0 s_0^j}{s_0^j}\right) \tag{33}$$

En la ecuación 33, j y k son enteros y la escala s_0 es una medida escalonada de la dilatación. Por otra parte el parámetro τ_0, va a depender de la medida escalonada de la dilatación. Generalmente la escala se va a establecer, en valores que hagan que el muestreo del eje de la frecuencia corresponda a un muestreo diádico.

Aunque las onduletas continuas puedan ser discretizadas, éstas no son en realidad onduletas discretas. El resultado de una onduleta continua discretizada, es una serie de coeficientes de onduletas, la cual es denominada *descomposición en series de onduletas.* Para que esta descomposición sea viable, las series tienen que poder reconstruir la señal original, y esto se logra condicionándolas mediante la imposición de límites positivos. Por último, y para deshacerse del problema de la redundancia, las onduletas discretas tienen que ser ortonormales, mediante de una buena selección de la onduleta madre [73]:

$$\int \Psi_{j,k}(t)\Psi^*_{m,n}(t)dt = \begin{cases} 1 & if \quad j = m \ and \ k = n \\ 0 & otherwise \end{cases} \tag{34}$$

Para resolver el segundo problema aquí mencionado, la solución más simple es no utilizar un número infinito de onduletas discretas. La traslación de las onduletas va a estar delimitado por la duración de la señal en investigación, es por tanto, que se debe establecer

el número de dilataciones (escalas) que se deben realizar para obtener un buen análisis de la señal en cuestión.

Es verdad que cada vez que la onduleta se alargue en el dominio del tiempo por un factor de 2, el ancho de banda analizado en el dominio de la frecuencia se ve reducido a la mitad, por lo que si se quisiera analizar todo el dominio de la frecuencia, se necesitaría de un número infinito de onduletas [73]. Para resolver este problema, se utiliza la función escalada, introducida por Mallat [79], con la cual una vez que el espectro de frecuencia haya sido cubierto casi en su totalidad por el espectro de las onduletas, se utiliza ésta función para cubrir el agujero, suficientemente pequeño, que no ha sido estudiado. Ver Fig. 32.

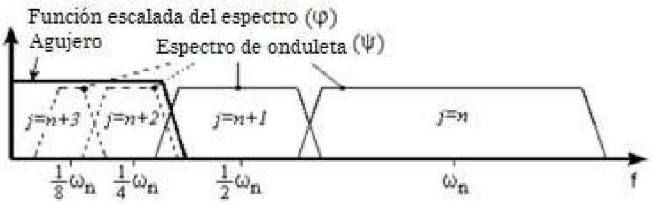

Figura 32: Uso de la función escalada [73]

Resumiendo la solución del problema 2 (número infinito de onduletas), si una onduleta puede ser vista como un filtro paso-banda y una función escalada como un filtro pasa-bajos, entonces las series de onduletas dilatadas juntas con la función escalada puede ser visto como un banco de filtros [73].

Si ya se estableció que el análisis de onduletas puede ser visto como un banco de filtros, entonces el tercer problema puede ser solucionado mediante el paso de la señal por diferentes filtros, elaborados de acuerdo como el investigador lo requiera. Ésta es una tarea muy tediosa, debido a que su principal desventaja es el diseño de cada filtro separadamente, lo cual consumirá mucho tiempo. En la siguiente sección se hablará de una manera más sencilla de filtrar la señal, mediante la técnica de *banco de filtración iterada*, en donde la mayor ventaja, recae en que las onduletas no se tienen que especificar explícitamente.

6.5 La Transformada de Onduleta Discreta (DWT)

En la sección anterior, la onduleta discreta de la cual se habló, es meramente el muestreo de una onduleta continua, debido a que solamente la traslación y la dilatación (escalas) fueron convertidas en discretas. Una onduleta es discreta cuando también la transformada de onduleta se discretiza. La ventaja de la transformada de onduleta discreta en comparación con una onduleta continua discretizada, es que ésta provee suficiente

el número de dilataciones (escalas) que se deben realizar para obtener un buen análisis de la señal en cuestión.

Es verdad que cada vez que la onduleta se alargue en el dominio del tiempo por un factor de 2, el ancho de banda analizado en el dominio de la frecuencia se ve reducido a la mitad, por lo que si se quisiera analizar todo el dominio de la frecuencia, se necesitaría de un número infinito de onduletas [73]. Para resolver este problema, se utiliza la función escalada, introducida por Mallat [79], con la cual una vez que el espectro de frecuencia haya sido cubierto casi en su totalidad por el espectro de las onduletas, se utiliza ésta función para cubrir el agujero, suficientemente pequeño, que no ha sido estudiado. Ver Fig. 32.

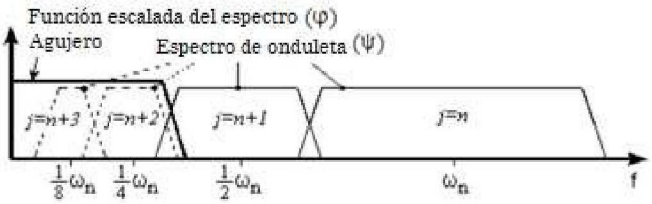

Figura 32: Uso de la función escalada [73]

Resumiendo la solución del problema 2 (número infinito de onduletas), si una onduleta puede ser vista como un filtro paso-banda y una función escalada como un filtro pasa-bajos, entonces las series de onduletas dilatadas juntas con la función escalada puede ser visto como un banco de filtros [73].

Si ya se estableció que el análisis de onduletas puede ser visto como un banco de filtros, entonces el tercer problema puede ser solucionado mediante el paso de la señal por diferentes filtros, elaborados de acuerdo como el investigador lo requiera. Ésta es una tarea muy tediosa, debido a que su principal desventaja es el diseño de cada filtro separadamente, lo cual consumirá mucho tiempo. En la siguiente sección se hablará de una manera más sencilla de filtrar la señal, mediante la técnica de *banco de filtración iterada*, en donde la mayor ventaja, recae en que las onduletas no se tienen que especificar explícitamente.

6.5 La Transformada de Onduleta Discreta (DWT)

En la sección anterior, la onduleta discreta de la cual se habló, es meramente el muestreo de una onduleta continua, debido a que solamente la traslación y la dilatación (escalas) fueron convertidas en discretas. Una onduleta es discreta cuando también la transformada de onduleta se discretiza. La ventaja de la transformada de onduleta discreta en comparación con una onduleta continua discretizada, es que ésta provee suficiente

información para el análisis y la síntesis de la señal original, con una reducción significante en el tiempo de cómputo [76].

La forma para discretizar la transformada de onduleta, es utilizando técnicas de filtros digitales. La señal pasará por una serie de filtros pasa-altos para analizar las frecuencias altas, y filtros pasa-bajos para analizar las frecuencias bajas.

La resolución de la señal, la cuál es la medida de la cantidad de los detalles de información en la señal, es cambiado por las operaciones de filtración, y la escala es cambiada mediante operaciones de submuestreo y sobremuestreo [76]. El submuestreo se refiere a la operación capaz de reducir la información que se tiene, ya sea mediante la reducción de la razón de muestreo o removiendo algunas de las muestras de la señal, de ésta forma la duplicación de datos se elimina. Ver Fig. 33 [75].

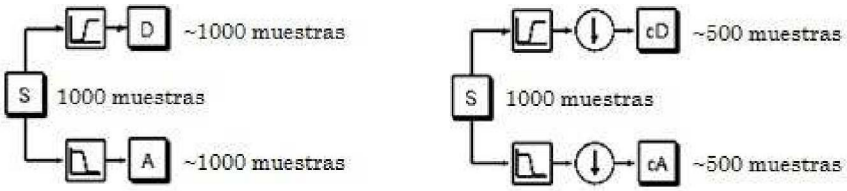

Figura 33: Técnica de submuestreo

La técnica de sobremuestreo sugiere incrementar la razón de muestreo de una señal insertando nuevas muestras a la señal, generalmente un valor de cero o un número interpolado. Ver Fig. 34 [75].

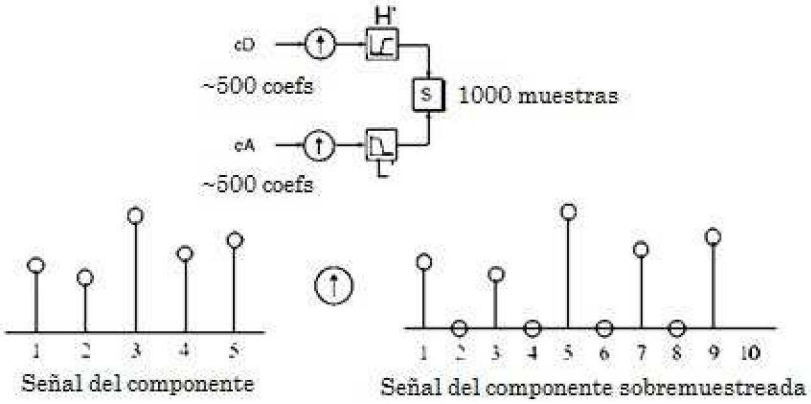

Figura 34: Técnica de sobremuestreo

La técnica del filtrado iterativo comienza con el paso de la señal a través un filtro digital pasa-bajos con una respuesta impulso *h[n]*, la cual divide la banda de frecuencia de la señal por la mitad. Filtrar una señal corresponde a la operación de convolución de la señal con una respuesta impulso del filtro [76], y se define de la siguiente manera:

$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] \cdot h[n-k] \tag{35}$$

Un punto importante a destacar en este momento, es la unidad de la frecuencia; aunque generalmente se habla de Hz, hay que mencionar que en señales discretas la unidad utilizada es radianes. El muestreo frecuencial de la señal es igual a 2π radianes, por lo tanto la componente frecuencial más alta que existe en una señal será de π radianes, siempre y cuando la señal sea muestreada a la razón Nyquist (la cual es, el doble de la frecuencia máxima que existe en la señal) [76].

Para dejar en claro completamente la diferencia entre resolución y escala, podemos decir que si una señal se pasa por un filtro pasa-bajos reduciendo la banda de frecuencias a la mitad, es decir, dejando como la frecuencia más alta $\pi/2$ radianes de acuerdo a la regla de Nyquist, significa que se remueve información de la frecuencia y la escala no cambia, sin embargo la resolución se ve afectada, debido a la pérdida de información de la señal. Ahora, que si la señal se submuestrea en una razón de 2, ésta tendrá la mitad de puntos, y la escala se modificará al doble, pero la resolución estaría intacta, debido a que remover la mitad de los componentes espectrales de la señal crea la mitad del número de muestras redundantes, en otras palabras, desechar la mitad de muestras no genera ninguna pérdida de información. Matemáticamente, esto puede ser expresado:

$$y[n] = \sum_{k=-\infty}^{\infty} h[k] \cdot x[2n-k] \tag{36}$$

El cómputo de la transformada de onduleta discreta, se realiza de la siguiente manera [70]: la señal es analizada en diferentes bandas de frecuencias con diferentes resoluciones mediante la descomposición de la señal en información detallada e información aproximada (las cuales están relacionadas con la función escalada y la función onduleta, previamente vistas). La señal original *x[n]* pasa primero a través de un filtro pasa-altos *g[n]* y un filtro pasa-bajos *h[n]*, que divide el ancho de banda de la frecuencial por la mitad, reduciendo así la frecuencia más alta que se encontraba en la señal. Una vez hecho esto, la señal puede ser submuestreada por 2, de manera que estos dos pasos constituyen el nivel uno de descomposición y matemáticamente pueden ser expresados de la siguiente manera:

$$y_{high}[k] = \sum_n x[n] \cdot g[2k-n] \tag{37}$$

$$y_{low}[k] = \sum_n x[n] \cdot h[2k-n] \tag{38}$$

Esta descomposición disminuye la resolución de tiempo y dobla la resolución de frecuencia, debido a que la banda de frecuencia de la señal se reduce a la mitad, reduciendo la incertidumbre de la frecuencia por la mitad. Esto es denominado el proceso de subbandeo (*subband coding*), y puede ser realizado varias veces para descomponer a la señal, presentando en cada descomposición las mismas características descritas (mitad de número de muestras = mitad de resolución de tiempo, y mitad de banda de frecuencia = doble de resolución de frecuencia) [76]. El proceso de descomposición se muestra en la Fig. 35.

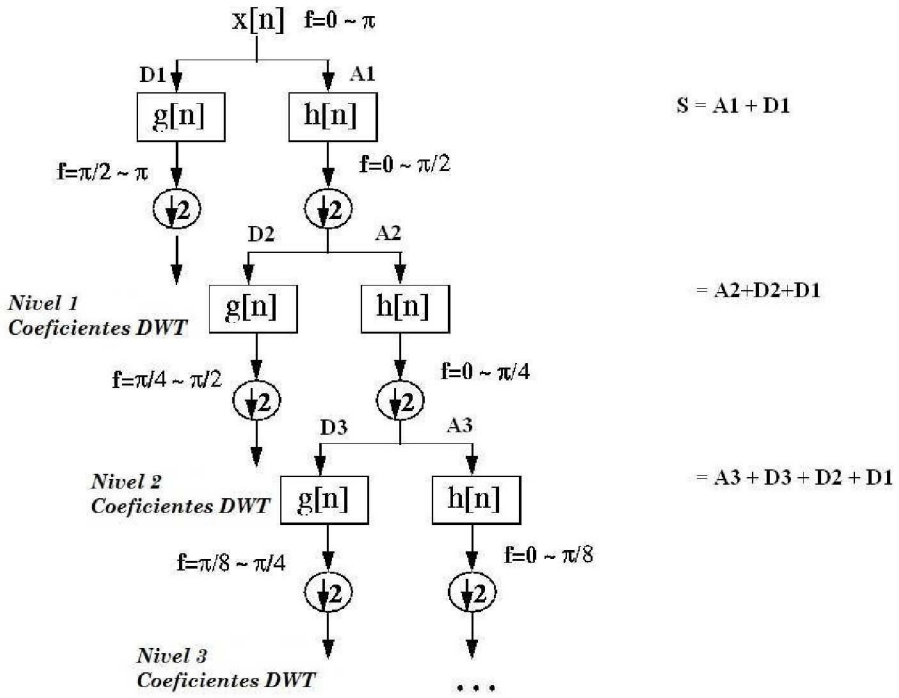

Figura 35: Proceso de descomposición de señal

Las frecuencias que son más prominentes en la señal original aparecerán con altas amplitudes en las regiones que incluyan esas frecuencias particulares en la DWT. La localización temporal tendrá una resolución que depende en el nivel en que éstas aparezcan. Si la información principal recae en altas frecuencias, la localización temporal de estas frecuencias será más precisa, debido a que se caracterizaron con un número mayor de muestras. Mientras tanto, si la información principal recae solo en frecuencias bajas, la localización temporal no será muy precisa, debido a que solo pequeñas muestras fueron utilizadas para expresar la señal en estas frecuencias. Este procedimiento ofrece buena resolución de tiempo en frecuencias grandes, y buena resolución de frecuencias en frecuencias bajas [76]. En la Fig. 36 [80], se muestra la técnica de DWT, aplicada en uno de sus campos más fructíferos: procesamiento de imágenes.

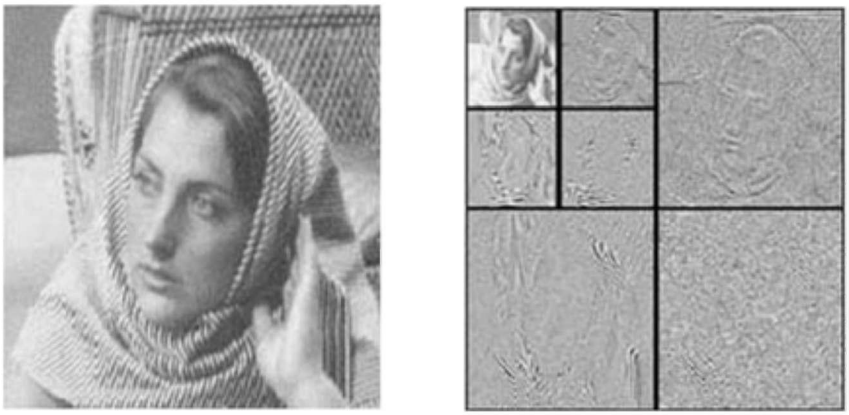

(a) (b)

Figura 36: (a) Imagen original "Barbara";
(b) Descomposición de imagen a través de DWT

6.6 Aplicación de la DWT en el proyecto de investigación

Como ya se explicó anteriormente, la causa de que modelos pasados realizados en esta investigación no hayan tenido buenos resultados, es por la forma en que los rasgos característicos fueron extraídos de la información que se tenía; los índices que se obtenían para ser insertados en los modelos de redes bayesianas, funcionaban para escenarios en donde se tenían 1 o 2 fallas, pero al tener más fallas simultáneas, los resultados se modificaban, acarreando un error en un "efecto cadena" que afectaba a los demás nodos, haciendo que su detección fuera incorrecta; por lo que se intentó otra técnica, las *onduletas*. Como ya se explicó en secciones anteriores, básicamente la teoría de onduletas, demanda que la señal estudiada sea tratada a través de filtros pasa-bajos y pasa-altos, para descomponer la señal en diferentes coeficientes con rasgos propios de cada frecuencia; en nuestro proyecto de investigación la información detallada de las señales estudiadas al ser demasiada y susceptible a los cambios o errores de un nodo, nos era en cierto punto, inservible para el estudio de la red industrial aquí utilizada, por lo que optamos por estudiar la señal a altas escalas, de manera que solamente se pudieran observar los rasgos generales de cada señal y los cambios que se producían en estos, al tener un determinado tipo de falla.

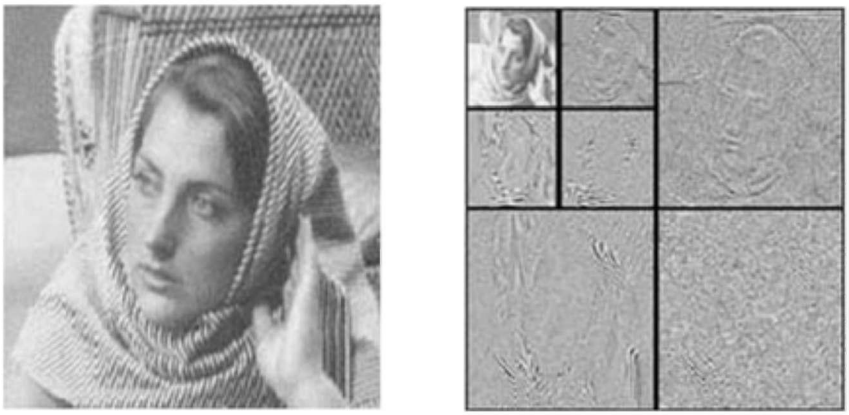

(a) (b)

Figura 36: (a) Imagen original "Barbara";
(b) Descomposición de imagen a través de DWT

6.6 Aplicación de la DWT en el proyecto de investigación

Como ya se explicó anteriormente, la causa de que modelos pasados realizados en esta investigación no hayan tenido buenos resultados, es por la forma en que los rasgos característicos fueron extraídos de la información que se tenía; los índices que se obtenían para ser insertados en los modelos de redes bayesianas, funcionaban para escenarios en donde se tenían 1 o 2 fallas, pero al tener más fallas simultáneas, los resultados se modificaban, acarreando un error en un "efecto cadena" que afectaba a los demás nodos, haciendo que su detección fuera incorrecta; por lo que se intentó otra técnica, las *onduletas*. Como ya se explicó en secciones anteriores, básicamente la teoría de onduletas, demanda que la señal estudiada sea tratada a través de filtros pasa-bajos y pasa-altos, para descomponer la señal en diferentes coeficientes con rasgos propios de cada frecuencia; en nuestro proyecto de investigación la información detallada de las señales estudiadas al ser demasiada y susceptible a los cambios o errores de un nodo, nos era en cierto punto, inservible para el estudio de la red industrial aquí utilizada, por lo que optamos por estudiar la señal a altas escalas, de manera que solamente se pudieran observar los rasgos generales de cada señal y los cambios que se producían en estos, al tener un determinado tipo de falla.

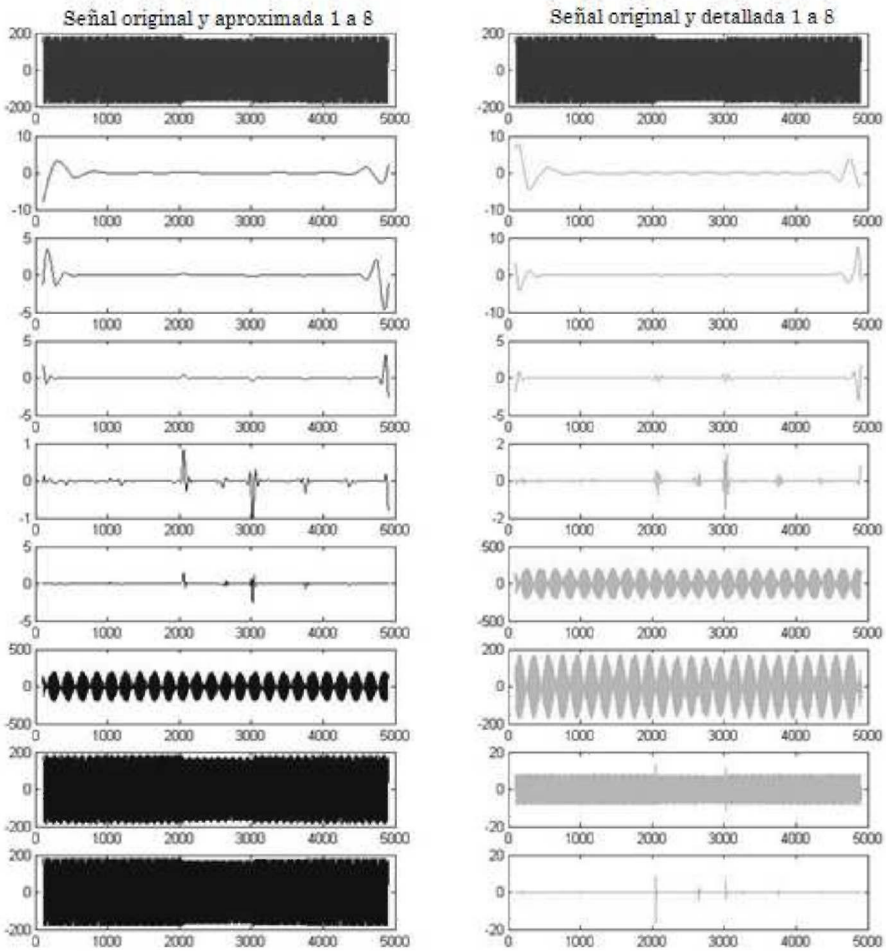

Figura 37: Onduletas de la fase A del nodo 3

En la Fig. 37 se puede observar un ejemplo realizado en Matlab, de la fase A del nodo 3 en funcionamiento normal y con falla. De lado izquierdo se pueden observar las onduletas creadas a altas escalas, es decir, información que solo nos deja ver el comportamiento general de la señal, mientras que de lado derecho se puede observar la información detallada de la señal. En las primeras descomposiciones (primeras en la ilustración) podemos observar, como es que los coeficientes de la onda, en realidad presentan poca información en comparación con las últimas descomposiciones; esto es lo que se estaba buscando, sacar una imagen global de la señal que no posea tanta información como la original, pero que sin embargo siguiera representando la dinámica de la onda, y lo más importante, que nos pudiera señalar que existía una anormalidad en su funcionamiento al momento de existir una falla; es por esto, que la primera descomposición, es la utilizada para la extracción de rasgos característicos en nuestra investigación. En la Fig. 38, simplemente mostramos la fase A del mismo nodo, pero ahora con una falla tipo A-Gnd, para que se observe la diferencia.

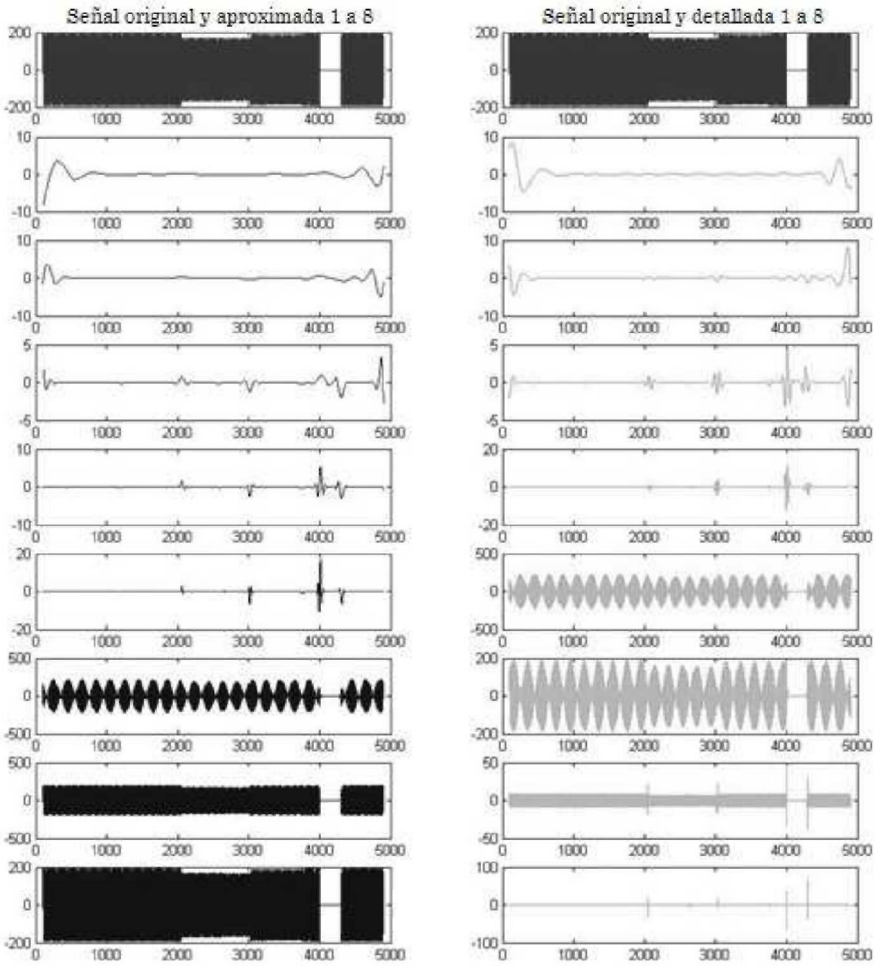

Figura 38: Onduletas fase A del nodo 3 con falla A-Gnd

El último punto importante del análisis de los datos que se realizaron, son los valores obtenidos por medio de ésta técnica, que a continuación se explicarán.

Los resultados obtenidos mediante la teoría de onduletas en la primera descomposición aplicada a los datos (ver Tabla C.3, en Apéndice C), fueron sumamente bondadosos, mostrando casi los mismos valores cuando existía una falla en la red, así también como cuando existían 5 fallas en la misma, quizás variando su valor en valores de centésimas y mostrándose diferentes, simplemente cuando existen los casos anormales de los cuáles ya se hablaron en la sección 3.2.2.

En la Tabla 21, se describen los resultados obtenidos a través de las onduletas para el nodo 1, como se puede apreciar los valores de las fases cambian cada vez que existe algún tipo de falla, sin embargo, solamente cambian en un valor de 0.2 unidades dependiendo si la fase se encuentra en su estado normal, línea a línea o fase a tierra, es decir, en la estructura bayesiana, se tendrá que realizar un determinado arreglo de las probabilidades, cuando se presenten una combinación de estos valores para determinar el tipo de falla que se tiene, pero además de eso, estos resultados son perfectamente utilizables en nuestra

estructura, y lo más importante, como ya se mencionó, estos valores permanecen casi estáticos, no importando el número de fallas que se tengan en la red.

Tipo de Falla	*Fase A*	*Fase B*	*Fase C*
Normal	4.0011	3.9982	3.998
AB	3.852	3.8424	3.998
AC	3.852	3.9982	3.849
BC	4.0011	3.8424	3.849
A-Gnd	3.7334	3.9982	3.998
B-Gnd	4.0011	3.7302	3.998
C-Gnd	4.0011	3.9982	3.7301
AB-Gnd	3.7334	3.7302	3.998
AC-Gnd	3.7334	3.9982	3.7301
BC-Gnd	4.0011	3.7302	3.7301
ABC-Gnd	3.7334	3.7302	3.7301

Tabla 21: Patrones de coeficientes obtenidos por DWT en el nodo 1

Para aclarar la manera en que los nuevos índices de falla son creados a partir de la teoría de onduletas, a continuación se da una breve explicación de su cálculo para esta aplicación en particular:

1. MicroTran como ya se ha comentado anteriormente, simula los escenarios de falla y genera 72 vectores con 5000 datos cada uno, correspondiente a las 3 fases de los 24 nodos (la prueba se realiza en un intervalo de tiempo de 5 segundos, con un período de muestreo de 1 ms),

2. Una vez que éstos se tienen, los datos son guardados en archivos que se puedan leer con el software Matlab,

3. Se corre un pequeño programa en donde solamente se realiza la primera descomposición de las onduletas (primer filtro pasa altos, ver Apéndice F), debido a que de esta manera ahorramos tiempo de cómputo y además, porque la primera descomposición de las onduletas muestra solamente la *silueta* o la *identidad* de la señal estudiada, y no sus detalles a fondo,

4. Una vez que el programa se corre, los coeficientes de onduletas individuales, de cada uno de los 5000 datos que se tenían, quedan almacenados en un vector; a este vector le es sacado el valor absoluto de cada uno de sus valores y se suman todos ellos, obteniendo así el índice de falla nuevo.

En cuanto a análisis de datos, se puede decir que lo aquí presentado es lo más relevante, describiendo el modelo utilizado en otra sección.

6.7 Décimo modelo: Descripción

El décimo modelo de Red Bayesiana Híbrida, basada en el resultado de la teoría de onduletas, aplicada individualmente a cada una de las señales, presenta la forma anteriormente utilizada, en donde la estructura es dividida en tres partes, cuyas funciones son:

- la parte superior tiene como función principal, el manejo de los datos discretos obtenidos a partir de los interruptores de protección de los nodos de la red eléctrica estudiada, y básicamente éstos nos dirán si en el nodo estudiado existe una falla o no, esto es, solamente se establecerá la existencia de una mal función, no el tipo de ésta,

- la parte inferior tiene como función, el manejo de los datos continuos y su transformación a datos discretos para que puedan ser comunicados con las demás partes de la red. Los datos insertados a esta sección, son obtenidos de las mediciones actuales de los voltajes que existan en la red eléctrica, de manera que haya datos que puedan identificar el tipo de falla y

- la parte media, es probablemente la más importante de la estructura de la red bayesiana, debido a que en ella se comunican los datos de las dos partes ya mencionadas y así se puede aislar y conocer, si es que existe, la falla en el nodo estudiado.

La Fig. 39 muestra el décimo modelo aquí descrito.

Como se puede observar en la Fig. 39, la parte superior en donde se trabajan los datos discretos, regresó a su forma inicial, en donde los datos de los interruptores de protección entran directamente a un solo nodo en donde se decide si en el nodo estudiado hay una falla o no. Aunque anteriormente se había hablado de la gran desventaja que esto nos genera (un gran número de probabilidades a detallar en la tabla condicional de probabilidad de los nodos), se decidió que era la manera más acertada y directa de tratar los datos discretos para un correcto diagnóstico de fallas en la red.

En la parte inferior, en donde se trabajan los datos continuos de los nodos de la red eléctrica, se puede observar que cada fase del voltaje de cada nodo debe ser tratada individualmente e insertada en el modelo independientemente, esto es debido a que posteriormente existe un nodo discreto en donde estos valores serán convertidos en valores discretos, para un mejor cálculo de las inferencias para detectar fallas. De acuerdo al análisis realizado en todos los nodos de la red eléctrica, las medias y varianzas en los nodos continuos del modelo, contienen datos que representan el estado normal, línea a línea, fase a tierra, caída BC y falla en otra fase, para su posterior uso en la detección del estado del nodo. (Ver Tablas 22, 23 y 24).

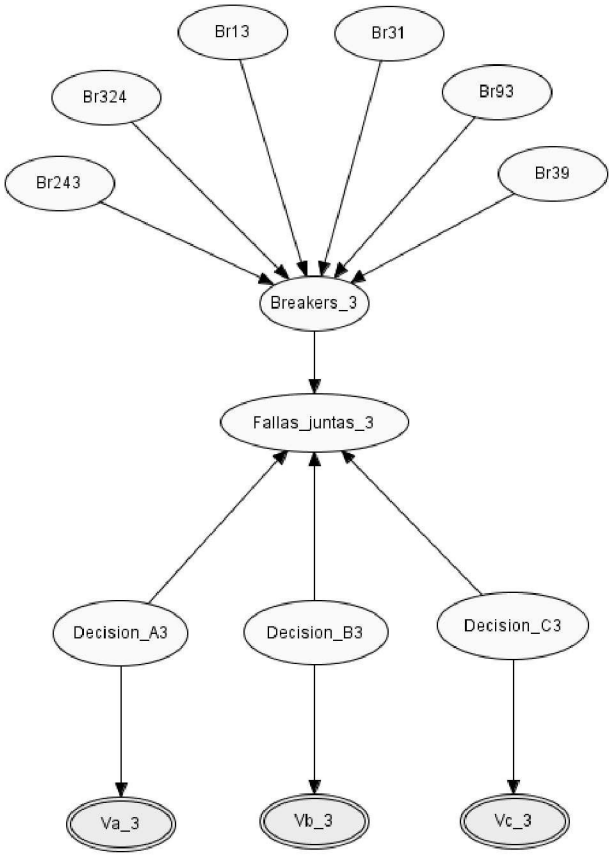

Figura 39: Décima estructura de RBH para la red eléctrica establecida

Decisión A	*Normal*	*Línea a Línea*	*Fase a Tierra*	*Falla en otra fase*
Media	5.63905	5.79269	5.61161	5.97716
Varianza	0.3	0.3	0.3	0.3

Tabla 22: Tabla condicional probabilística de la fase A del Nodo 3

Decisión B	*Normal*	*Línea a Línea*	*Fase a Tierra*	*Falla en otra fase*
Media	5.63543	5.78903	5.60329	5.97377
Varianza	0.3	0.3	0.3	0.3

Tabla 23: Tabla condicional probabilística de la fase B del Nodo 3

Decisión C	*Normal*	*Línea a Línea*	*Fase a Tierra*	*Falla en otra fase*
Media	5.64217	5.79466	5.60895	5.97974
Varianza	0.3	0.3	0.3	0.3

Tabla 24: Tabla condicional probabilística de la fase C del Nodo 3

La parte media de la estructura, contiene una detallada selección de probabilidades, en donde dependiendo del estado individual de cada fase del voltaje obtenido en las lecturas (ver sección 6.6 y Tabla C.3 en Apéndice C) y la lectura de los interruptores de protección, se calcula el estado del nodo en general y nos da un posible resultado. Las posibles combinaciones que se pueden obtener (viéndolas de una manera compacta), se especifican en la Tabla 25.

Posibles Decisiones	*Fase A*	*Fase B*	*Fase C*	*Breakers*	*Tipo de Falla*
1	Normal	Normal	Normal	OK	Normal / Sin Falla
2	Línea a línea	Línea a línea	Falla en otra fase / Normal	Falla	A-B
3	Falla en otra fase / Normal	Caída BC / Línea a línea	Caída BC / Línea a línea	Falla	B-C
4	Línea a línea	Falla en otra fase / Normal	Línea a línea	Falla	A-C
5	Fase a tierra	Falla en otra fase / Normal	Falla en otra fase / Normal	Falla	A-Gnd
6	Falla en otra fase / Normal	Fase a tierra	Falla en otra fase / Normal	Falla	B-Gnd
7	Falla en otra fase / Normal	Falla en otra fase / Normal	Fase a tierra	Falla	C-Gnd
8	Fase a tierra	Fase a tierra	Falla en otra fase / Normal	Falla	AB-Gnd
9	Fase a tierra	Falla en otra fase / Normal	Fase a tierra	Falla	AC-Gnd
10	Falla en otra fase / Normal	Fase a tierra	Fase a tierra	Falla	BC-Gnd
11	Fase a tierra	Fase a tierra	Fase a tierra	Falla	ABC-Gnd

Tabla 25: Únicas posibles combinaciones para determinar tipo de falla presentada

Como se puede observar en la Tabla 25, ésas son las únicas posibles combinaciones que se resaltan en la TPC, las demás combinaciones existentes se descartan, dándoles una probabilidad muy pequeña de incidencia para que no aparezcan en los resultados finales.

6.8 Evaluación Décimo Modelo

Los resultados son satisfactorios; como se podrá observar en el siguiente capítulo, en donde los porcentajes que se obtienen son muy altos en la detección de

La parte media de la estructura, contiene una detallada selección de probabilidades, en donde dependiendo del estado individual de cada fase del voltaje obtenido en las lecturas (ver sección 6.6 y Tabla C.3 en Apéndice C) y la lectura de los interruptores de protección, se calcula el estado del nodo en general y nos da un posible resultado. Las posibles combinaciones que se pueden obtener (viéndolas de una manera compacta), se especifican en la Tabla 25.

Posibles Decisiones	*Fase A*	*Fase B*	*Fase C*	*Breakers*	*Tipo de Falla*
1	Normal	Normal	Normal	OK	Normal / Sin Falla
2	Línea a línea	Línea a línea	Falla en otra fase / Normal	Falla	A-B
3	Falla en otra fase / Normal	Caída BC / Línea a línea	Caída BC / Línea a línea	Falla	B-C
4	Línea a línea	Falla en otra fase / Normal	Línea a línea	Falla	A-C
5	Fase a tierra	Falla en otra fase / Normal	Falla en otra fase / Normal	Falla	A-Gnd
6	Falla en otra fase / Normal	Fase a tierra	Falla en otra fase / Normal	Falla	B-Gnd
7	Falla en otra fase / Normal	Falla en otra fase / Normal	Fase a tierra	Falla	C-Gnd
8	Fase a tierra	Fase a tierra	Falla en otra fase / Normal	Falla	AB-Gnd
9	Fase a tierra	Falla en otra fase / Normal	Fase a tierra	Falla	AC-Gnd
10	Falla en otra fase / Normal	Fase a tierra	Fase a tierra	Falla	BC-Gnd
11	Fase a tierra	Fase a tierra	Fase a tierra	Falla	ABC-Gnd

Tabla 25: Únicas posibles combinaciones para determinar tipo de falla presentada

Como se puede observar en la Tabla 25, ésas son las únicas posibles combinaciones que se resaltan en la TPC, las demás combinaciones existentes se descartan, dándoles una probabilidad muy pequeña de incidencia para que no aparezcan en los resultados finales.

6.8 Evaluación Décimo Modelo

Los resultados son satisfactorios; como se podrá observar en el siguiente capítulo, en donde los porcentajes que se obtienen son muy altos en la detección de

la falla correcta en el nodo correcto, esto es debido a una extracción correcta de datos importantes de los datos analizados para realizar el modelo.

Aunque los porcentajes de diagnóstico son muy altos, aún existen algunas fallas no identificadas correctamente, esto debido a que la interrelación que existe entre los nodos de la red eléctrica no puede ser suprimida del todo, siempre habrá una especie de efecto en cadena, que se presentará en la red.

CAPÍTULO 7
Resultados

7.1 Sinopsis

Al igual que en el capítulo 4, y con el modelo ocho, una vez que el décimo modelo en pequeña escala funciona adecuadamente, se puede realizar su expansión a todos los nodos de la red. En la siguiente sección se muestra el modelo completo de la red eléctrica transformado en una estructura de RBH. Los porcentajes de eficiencia para la validación del modelo son presentados en la sección 3, así también como una comparación con otros métodos de 2 etapas parecidos al aquí utilizado, para condiciones ideales y en la sección 4, se realiza lo mismo pero para condiciones en donde exista ruido, para comprobar la robustez del modelo.

7.2 Modelo de la red eléctrica completa

Al obtener resultados eficientes con la extracción de rasgos característicos de los datos y una buena estructura bayesiana, el siguiente paso, fue realizar este modelo en gran escala, es decir, aplicarlo a toda la red estudiada. El diagrama se puede observar en la Fig. 40.

Entre los puntos importantes que podemos destacar en este modelo de la red completa, tenemos:

- A diferencia del modelo presentado en el capítulo 4, en este modelo no existe la necesidad de relacionar los nodos individuales en otro aspecto que no sea en los interruptores de protección, es decir, el hecho de que se presente una falla simple no afecta de una manera significativa el índice de falla de otros nodos, haciendo que prácticamente cada nodo funcione de una manera independiente uno de otro.

- Se utilizaron 3 nodos continuos para la inserción de datos de los índices de falla en el modelo de RBH, lo cual en modelos pasados había causado problemas, sin embargo, aquí se cambiaron dos cosas: a) los nodos continuos no tienen otros padres o hijos continuos, quitando el problema de las varianzas y su cálculo, y b) una vez que entran a la RBH, prácticamente son convertidos en datos discretos por el nodo que se encuentra entre ellos y la parte intermedia del modelo, convirtiendo así la detección de fallas en una tarea más fácil.

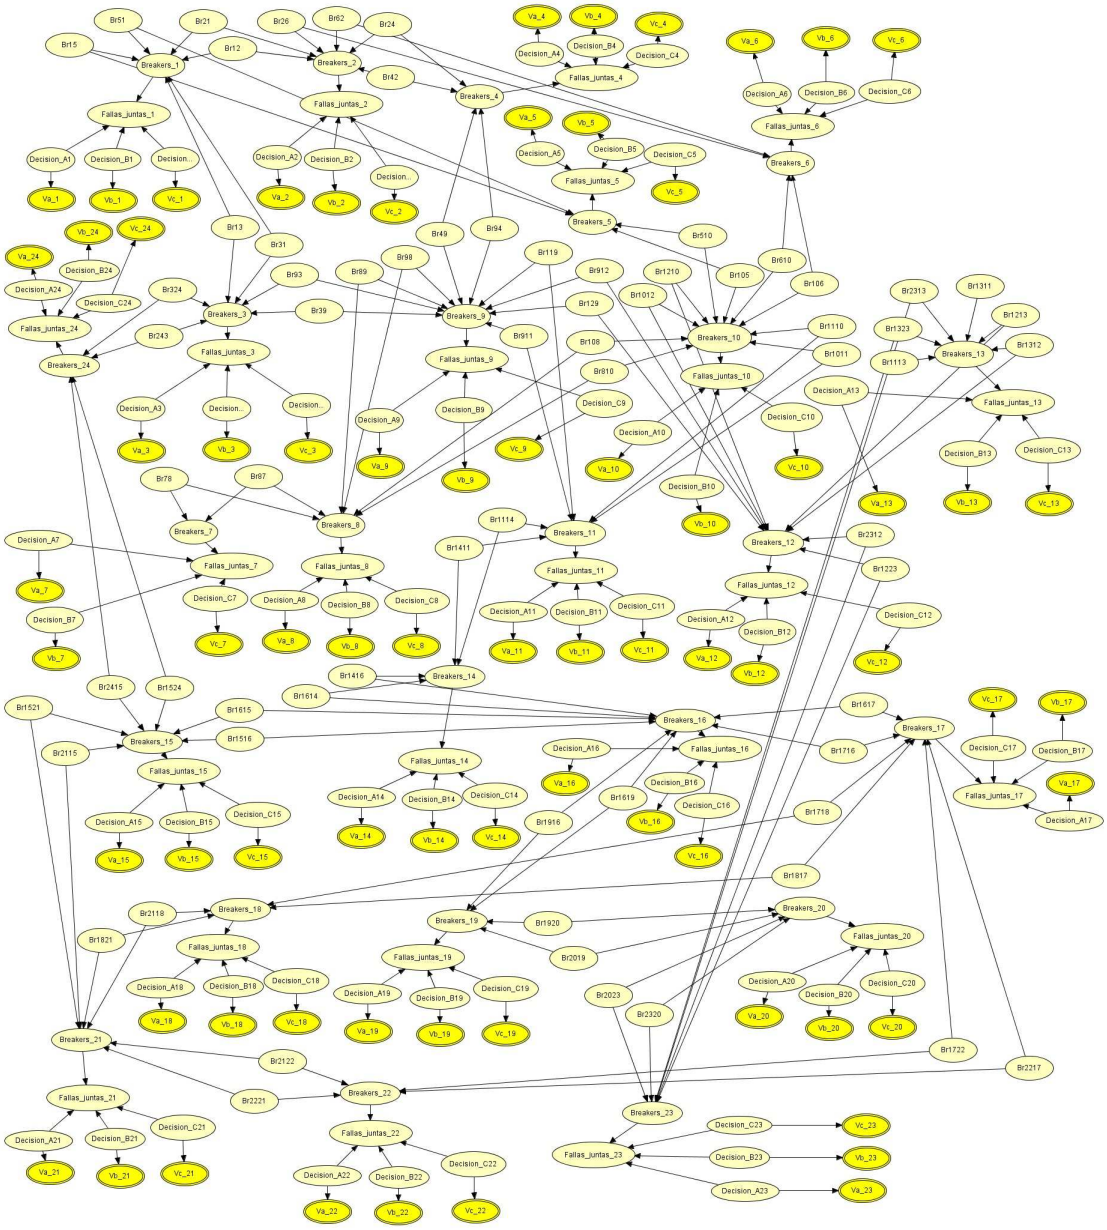

Figura 40: Estructura completa de RBH con modelo 10 para la red eléctrica establecida

7.3 Pruebas y resultados en condiciones ideales

Se realizaron 3 evaluaciones del modelo 10 de RBH. En la primera evaluación se realizaron 25 pruebas de fallas simples y simultáneas (de 2 a 5 fallas); las fallas presentadas fueron elegidas aleatoriamente y pueden ser del tipo línea-línea, una-dos y

tres-fases a tierra (Tabla D.1, Apéndice D). De estos 10 escenarios de falla, 5 fueron utilizados para el entrenamiento de la RBH y 5 fueron utilizados propiamente para la validación del modelo.

Los datos continuos (voltajes) se generaron con el software MicroTran y los estados discretos de los interruptores de protección se tomaron del resultado de una simulación Montecarlo. Se dice que estas pruebas son realizadas bajo *condiciones ideales*, debido a que estamos considerando que los interruptores siempre nos dan la información correcta que se lee de la red y éstos funcionan correctamente, y los datos continuos son leídos sin problemas.

No. De Fallas	*% Eficiencia*
1 Falla	100
2 Fallas	90
3 Fallas	86.67
4 Fallas	80
5 Fallas	96

Tabla 26: Porcentaje de eficiencia en primera evaluación

No. Fallas/ Tipo de Fallas	*1 Falla*		*2 Fallas*		*3 Fallas*		*4 Fallas*		*5 Fallas*		*%*
	Cor-recto	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	*Cor-recto*	*Incor-recto*	
A-B	1	0	2	0	3	0	2	0	2	1	90.91
A-C	1	0	1	0	0	0	0	1	4	0	85.71
B-C	0	0	0	1	1	2	1	0	4	0	66.67
A-Gnd	0	0	0	0	1	0	2	0	2	0	100.0
B-Gnd	0	0	0	0	1	0	1	1	0	0	66.67
C-Gnd	2	0	0	0	1	0	0	2	4	0	77.78
AB-Gnd	1	0	2	0	2	0	1	0	0	0	100.0
AC-Gnd	0	0	2	0	1	0	2	0	1	0	100.0
BC-Gnd	0	0	2	0	1	0	5	0	1	0	100.0
ABC-Gnd	0	0	0	0	2	0	2	0	6	0	100.0

Tabla 27: Porcentaje de eficiencia por tipo de falla

Las Tablas 26 y 27 nos muestran los porcentajes de eficiencia presentados en esta primera evaluación de validación del modelo. Hablando en términos generales, se puede decir que el modelo detecta 67 escenarios de falla correctamente de un total de 75, dando como porcentaje general un 89.33%, presentando un desempeño 36% mejor que el presentado en las Tablas 12 y 13 del capítulo 4. Como se puede observar en la Tabla 27, las fallas con más problemática de detectar en este modelo son la línea a línea (B-C) y una fase a tierra (B Gnd), sin embargo ningún porcentaje se encuentra por debajo de la mitad de los casos, mostrando resultados exitosos. La comparación entre el modelo RBH de la octava estructura y el modelo RBH con WT de la décima estructura, puede ser observada en las Fig. 41 y 42.

En las siguientes dos evaluaciones realizadas, se realizaron 48 simulaciones, en la red eléctrica seleccionada, en donde aleatoriamente se seleccionaron un conjunto de 4 nodos

de prueba (nodos 3, 9, 10 y 13) y se probó el modelo aquí realizado para su comparación con el modelo presentado en el sistema de identificación de Garza [2], basado en Redes Bayesianas Discretas y modelos probabilísticos de máxima entropía.

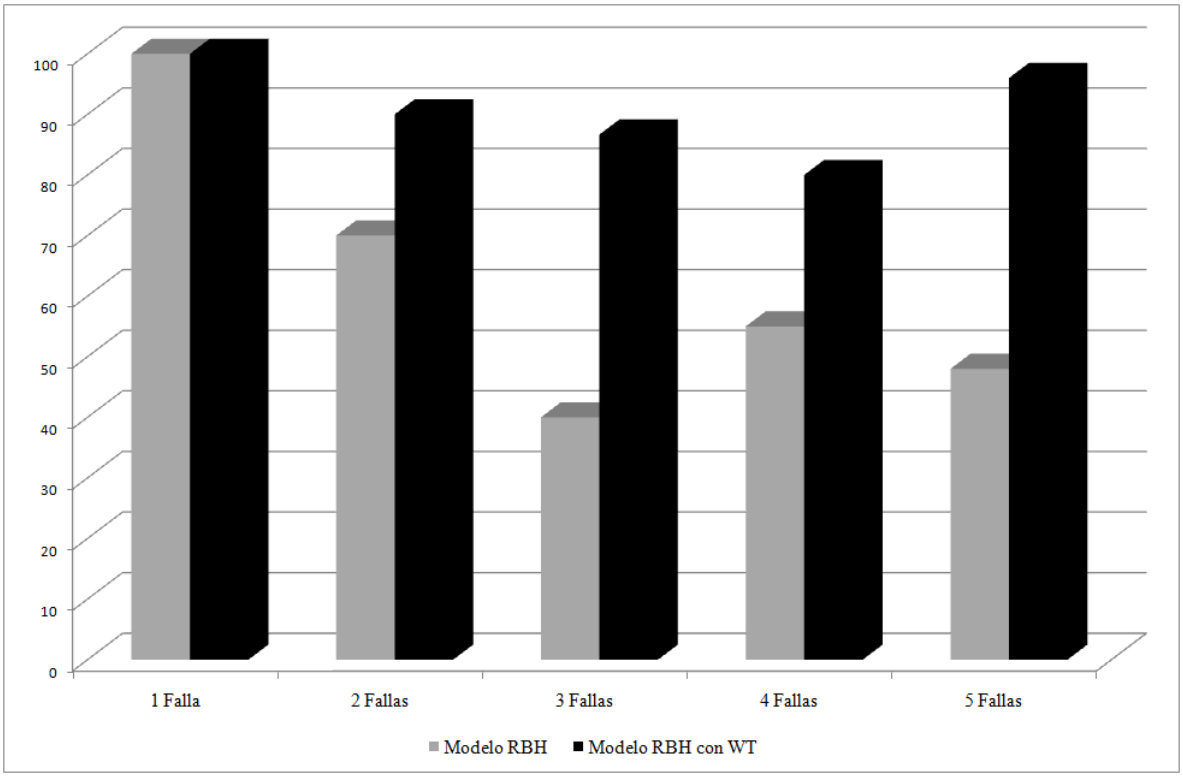

Figura 41: Gráfica de comparación por número de fallas

Las simulaciones fueron divididas para realizar dos tipos de pruebas. En la primera evaluación, cada simulación incluía uno de los cuatro nodos elegidos previamente para prueba con alguna falla aleatoria (línea a línea, una, dos o tres fases a tierra), y fallas aleatorias en otros nodos. La prueba de eficiencia, gira en torno a la determinación correcta del estado del nodo de prueba. La segunda evaluación consistió en la simulación de fallas aleatorias de los 4 nodos de prueba y la identificación correcta del estado de cada nodo. En ambas evaluaciones, el estado del interruptor de seguridad fue determinado por la selección aleatoria de uno de sus tres estados: OPEN, FAIL, OK.

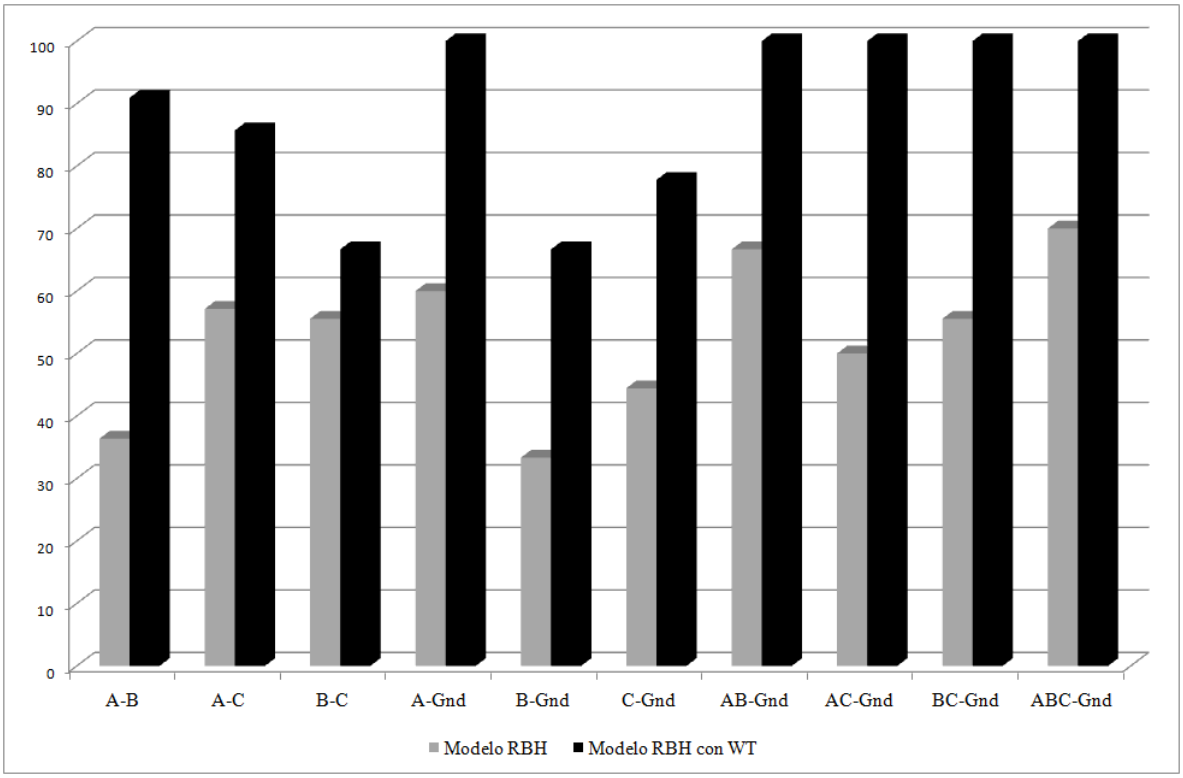

Figura 42: Gráfica de comparación por tipo de falla

En las Tablas 28, 29, 30 y 31, se muestran los resultados de la segunda (Tabla D.2, Apéndice D) y tercera prueba (Tabla D.3, Apéndice D).

	Modelo RBH			*Modelo DICL-DPM*		
Estado del nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
A-B-C Gnd	4	0	100.0	4	0	100.0
A-B Gnd	2	0	100.0	2	0	100.0
A Gnd	4	1	80.0	4	1	80.0
A-B	4	0	100.0	3	1	75.0
B-C	6	0	100.0	6	0	100.0
No Fault	3	0	100.0	3	0	100.0

Tabla 28: Evaluación 2 por tipo de falla

	Modelo RBH			*Modelo DICL-DPM*		
Número de nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
3	6	0	100.0	6	0	100.0
9	6	0	100.0	6	0	100.0
10	5	1	83.33	4	2	66.7
13	6	0	100.0	6	0	100.0

Tabla 29: Evaluación 2 por nodo

	Modelo RBH			*Modelo DICL-DPM*		
Estado del nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
A-B-C Gnd	14	0	100.0	14	0	100.0
A-B Gnd	10	0	100.0	10	0	100.0
A Gnd	14	0	100.0	12	2	85.7
A-B	16	2	88.89	15	3	83.3
B-C	13	3	81.25	16	0	100.0
No Fault	24	0	100.0	17	7	70.8

Tabla 30: Evaluación 3 por tipo de falla

	Modelo RBH			*Modelo DICL-DPM*		
Número de nodo	*Correcto*	*Equivocado*	*% Exactitud*	*Correcto*	*Equivocado*	*% Exactitud*
3	24	0	100.0	19	5	79.1
9	22	2	91.67	21	3	87.5
10	21	3	87.5	21	3	87.5
13	24	0	100.0	23	1	95.8

Tabla 31: Evaluación 3 por nodo

Como se puede observar en las tablas aquí vistas, no solamente los porcentajes son muy altos, sino que prácticamente sobrepasan la eficiencia mostrada por el modelo de Garza [2]. Sin embargo, los resultados del modelo comparado que fueron aquí presentados, ya contenían señales con ruido, especialmente en la información proporcionada por los interruptores de protección de los nodos, y por tanto no estaban en condiciones ideales, por lo que se realizó otra comparación con un método, en donde las condiciones de falla y prueba eran más parecidas a las que en esta sección se requerían. La comparación entre el modelo RBH con WT y el modelo DICL-DPM, puede ser observada en las Figs. 43, 44, 45 y 46.

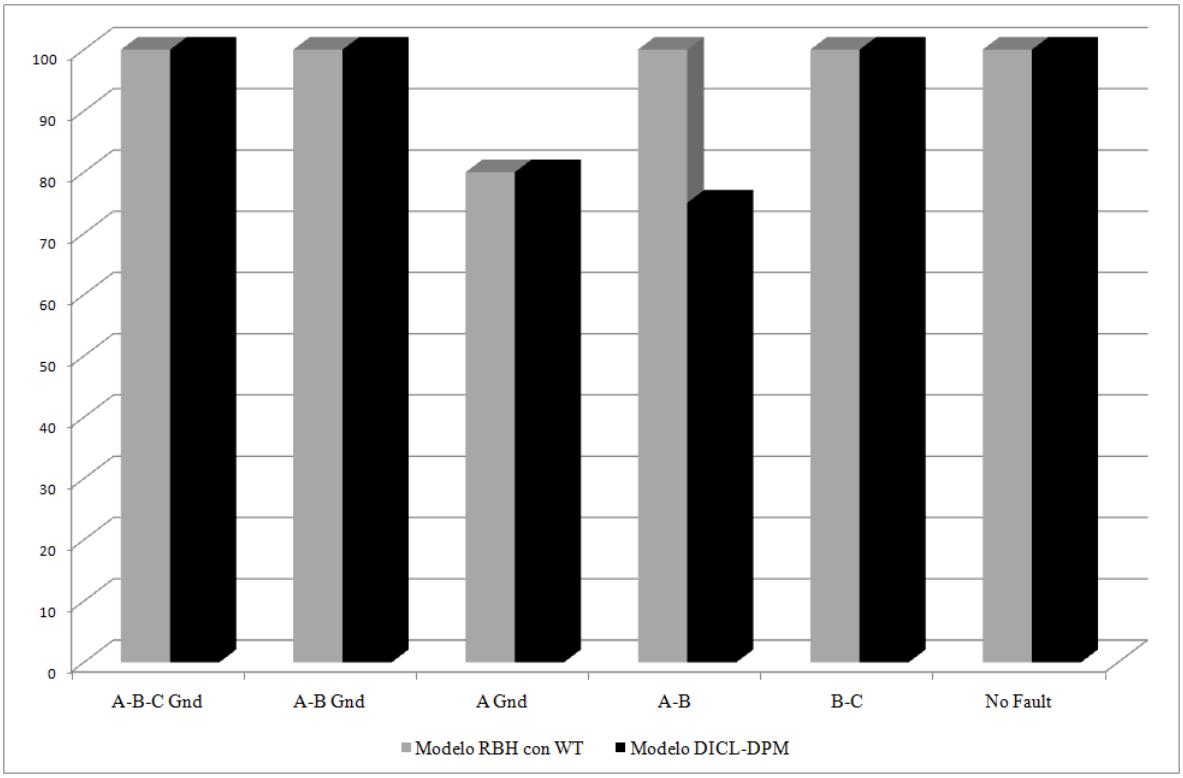

Figura 43: Gráfica de evaluación 2 por tipo de falla

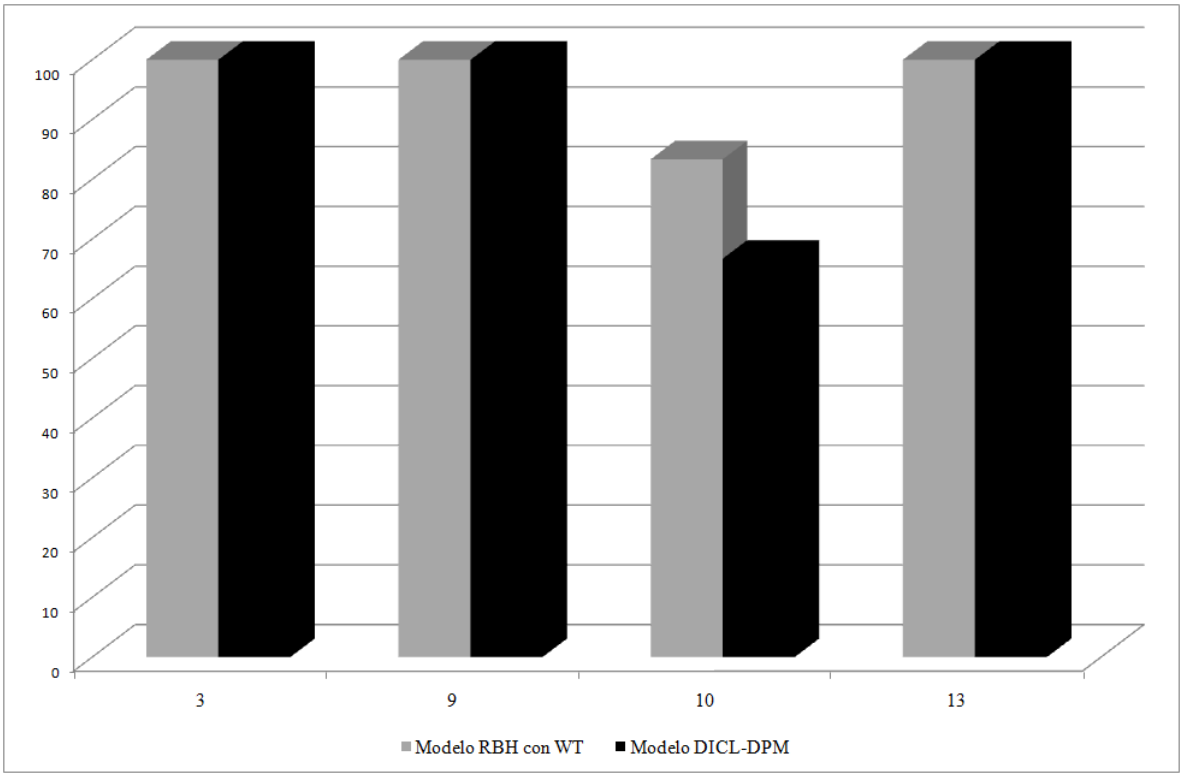

Figura 44: Gráfica de evaluación 2 por nodo

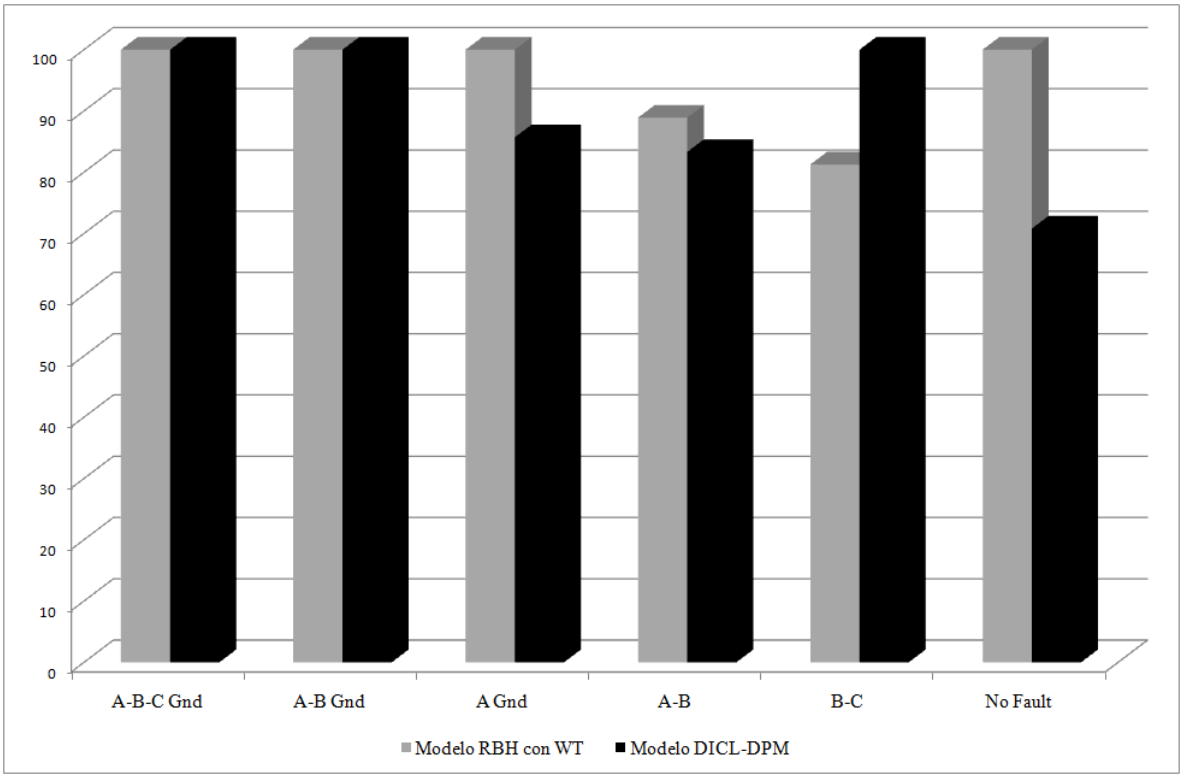

Figura 45: Gráfica de evaluación 3 por tipo de falla

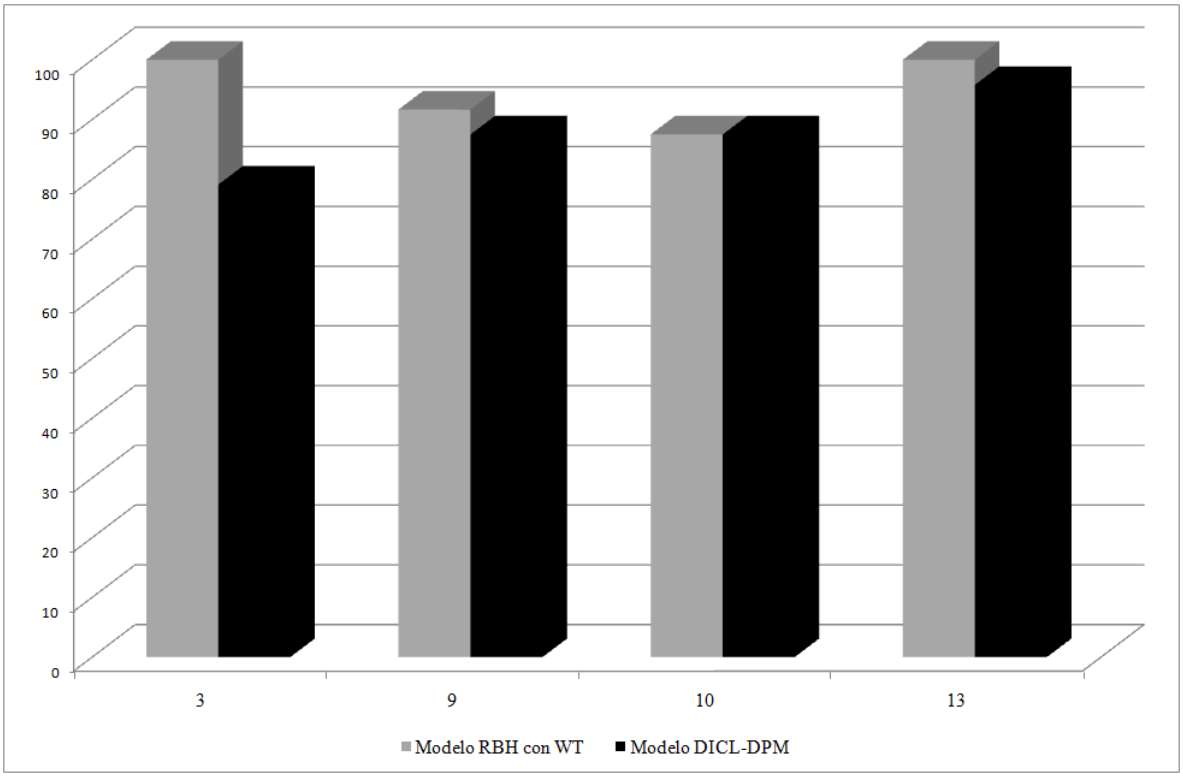

Figura 46: Gráfica de evaluación 3 por nodo

En las Tablas 32 y 33, se presenta la comparación de los resultados de este trabajo con la investigación realizada en [81]. En esta investigación, 3 evaluaciones con diferentes tipos de muestreo en los mismos escenarios de falla, fueron realizadas. Aquí se presentan los resultados de estas 3 pruebas en comparación con lo obtenido por este proyecto. Los escenarios de falla que se utilizaron en esas pruebas fueron los contenidos en la Tabla D.3, del Apéndice D.

Tipo de Falla	*Caso 1*	*Caso 2*	*Caso 3*	*Modelo RBH*
A-B-C Gnd	100.0	100.0	100.0	100.0
A-B Gnd	100.0	100.0	100.0	100.0
A Gnd	100.0	85.7	92.9	100.0
A-B	100.0	83.3	50.0	88.9
B-C	100.0	68.8	68.8	81.3
No Fault	54.2	58.3	79.2	100

Tabla 32: Porcentaje de Eficiencia por tipo de falla

Número de nodo	*Caso 1*	*Caso 2*	*Caso 3*	*Modelo RBH*
3	83.3	83.3	83.3	100.0
9	79.2	75.0	70.8	91.7
10	91.2	87.5	62.5	87.5
13	100.0	95.8	100.0	100.0

Tabla 33: Porcentaje de Eficiencia por número de nodo

En las Tablas 32 y 33 se puede observar cómo es que en un nivel general el modelo aquí propuesto, presenta mejores resultados. Podemos comparar por ejemplo, de la tabla 28 el Caso 1, que es el que mejor porcentaje de eficiencia tiene (88.54% porcentaje general), con 85 casos correctamente detectados de 96 escenarios de falla, con el modelo aquí propuesto que presenta solamente 5 casos mal detectados, es decir 91 casos correctamente diagnosticados, de un total de 96 escenarios de falla, dando como porcentaje general de éxito un 94.79%, en esta evaluación. En la investigación de [81], el modelo presenta cierto tipo de degradación en sus resultados, principalmente por la similitud de algunos de sus datos procesados, cuando hay más datos de operación en estado normal que en estado de falla (Caso 2 y 3), este tipo de desventaja no es presentado en nuestro modelo.

Se puede concluir que el modelo es viable bajo condiciones ideales, y presenta mejores resultados que algunos otros modelos existentes.

7.4 Pruebas y resultados en condiciones no-ideales y presencia de ruido

En la sección anterior se hicieron pruebas con condiciones ideales, es decir, se supuso que los datos que nuestra red eléctrica industrial daba al sistema de detección de fallas, eran correctos, no había falta de información y la instrumentación (hardware) funcionaba correctamente. En esta sección se pretenden presentar las 3 evaluaciones realizadas a los demás modelos, pero en este caso con ruido. El ruido utilizado para estas pruebas, fue dado por los Interruptores de protección, y consistía básicamente, de una probabilidad errónea en los nodos discretos en donde, el hardware no siempre daba el estado actual del interruptor, es decir, podía marcar que un interruptor se abría o mostraba un malfuncionamiento, aunque los nodos estuvieran trabajando correctamente o viceversa. A continuación se muestran los resultados obtenidos.

En la primera prueba realizada, la cual consistía en 10 pruebas de 1 a 5 fallas, en donde, 5 eran utilizadas para las pruebas y 5 para la validación del modelo, los resultados fueron los mostrados en la Tabla 34. La primera columna de la tabla, representa el número de fallas que fueron simuladas para cada escenario; la siguiente columna muestra el número total de nodos que poseían una falla; la tercera columna muestra el número de detecciones correctas de fallas por el modelo aquí propuesto; la cuarta columna muestra los nodos que marcaron falsos positivos en la prueba, esto es, nodos que dependiendo del valor del nodo discreto de los interruptores de protección, marcaban una falla, aún cuando esta no existía; la quinta columna, marca los falsos negativos, esto es nodos que tenían fallas y dependiendo del valor del nodo discreto, algunas veces mostraba que el nodo estaba funcionando adecuadamente cuando en realidad poseía una falla; la sexta columna, muestra en porcentaje, el desempeño del modelo propuesto, en cuanto a detectar fallas se refiere y la última columna, muestra el porcentaje de error del modelo, es decir, cuántos falsos positivos y negativos capta la estructura propuesta.

# Fallas	*# Nodos*	*Detección Correcta*	*Falsos Positivos*	*Falsos Negativos*	*% Eficiencia*	*% Error*
1 Falla	5	5	1	0	100.0	0.9
2 Fallas	10	8	1	1	80.0	1.8
3 Fallas	15	13	11	0	80.0	10.0
4 Fallas	20	17	14	2	85.0	16.0
5 Fallas	25	14	8	11	56.0	18.0

Tabla 34: Porcentaje de eficiencia en primera evaluación

Si comparamos la Tabla 26 con la 34, podemos observar que la detección de las fallas en los nodos afectados (a excepción de los escenarios con 5 fallas simultáneas) no presenta cambios muy significativos, debido a que la mayor pérdida de eficiencia esta dada en la detección de 2 fallas simultáneas, la cual es de 10 %, y se encuentra dentro del rango aceptable para el modelo, sin embargo, el% de error que se tiene del modelo para la detección de falsos positivos y negativos, es muy pronunciada en los escenarios en donde existen desde 3 fallas simultáneas. Obviamente, la reacción en cadena afecta los índices de los nodos vecinos a los nodos que tienen malfuncionamiento, y si aunado a eso, no se tiene

la lectura correcta del modelo o si los sensores o interruptores de seguridad presentan fallas, el modelo empezará a diagnosticar cosas que no están sucediendo. Cabe mencionar que la eficiencia de detección de fallas total de la Tabla 34 es del 76 %, mientras que la presentada en la tabla 26 es de 89.33 %, aunque es un cambio algo significativo, el modelo aún presenta un nivel aceptable de detección de fallas.

La siguiente prueba realizada, fue la creación de 24 escenarios de prueba, en donde sólo se desea detectar fallas en los nodos de prueba 3, 9, 10 y 13. Solamente se desea detectar la falla en 6 escenarios para cada nodo; los demás nodos pueden o no presentar fallas simultáneamente, pero en esta evaluación no son tomados en cuenta. En la Tabla 35, se muestran los resultados de esta prueba. La tabla está compuesta por 10 columnas, la primera denota el nodo en el cual se está haciendo el análisis; la segunda muestra la cantidad de escenarios de falla que se analizaron en cada nodo de prueba; la tercera columna muestra los escenarios de falla correctamente detectados por el modelo propuesto; los falsos positivos, es decir, cuando fallas son detectadas en los nodos de prueba y en los escenarios de prueba predeterminados, aún y cuando la falla no exista, son mostrados en la columna número cuatro; la quinta columna muestra los falsos negativos, esto es, cuando el modelo no detecta fallas que en realidad están sucediendo en los nodos de prueba y en los períodos de prueba predeterminados; la sexta columna muestra el% de eficiencia, que el modelo presentó para detectar correctamente las fallas presentadas en los nodos de prueba; en la séptima, octava y novena columna se muestra si en alguno de los nodos de prueba, la estructura aquí propuesta no fue capaz de detectar el correcto estado de funcionamiento del mismo, mostró falsos positivos o falsos negativos, pero en los escenarios que no fueron determinados para su validación y en la última columna se muestra el% de Error que el modelo presenta para los nodos de prueba, es decir, el porcentaje de los estados mal detectados sobre el total de los escenarios que se tienen.

# Nodo	*# Escenarios*	*Detectados*	*Falsos Positivos*	*Falsos Negativos*	*% Eficiencia*	*Incorrecto*	*Falsos Positivos*	*Falsos Negativos*	*% Error*
3	6	6	0	0	100.0	0	7	2	50.0
9	6	4	0	3	66.67	0	8	0	44.44
10	6	3	0	3	50.0	5	2	0	38.89
13	6	6	0	0	100.0	0	0	0	0.0

Tabla 35: Evaluación 2 por nodo

Si comparamos la Tabla 29 con la 35, podemos observar que la prueba realizada en condiciones no ideales no es nada bondadosa con los resultados, y ahora el cambio de eficiencia en los nodos 9 y 10, es muy significativo. Los porcentajes de error que aparecen en la última columna, aunque son altos, pertenecen a nodos más problemáticos que los demás, por lo que, si viéramos el panorama general de toda la red, observaríamos que el porcentaje de error total es de 12.0% (10 casos de un mal diagnóstico del estado de los nodos y 55 de falsos positivos y negativos, de un total de 552 casos). Por lo que tal vez, la medición en estos nodos no es tan representativa del sistema, pero cabe mencionar que se tomaron en cuenta para poder hacer comparaciones con otros modelos (realizar las mismas pruebas) y realmente observar que tan eficiente la estructura propuesta. La eficiencia global, obtenida por esta prueba, es de 79.17 %, mientras que la obtenida por condiciones ideales es de 95.83%, lo cual muestra que si hay una caída de eficiencia notable.

La última tabla que se escribirá, es la de la evaluación 3, en donde solamente existen fallas simples o simultáneas en los nodos de prueba, y los demás nodos están en estado normal de funcionamiento. Se realizaron 24 pruebas, en donde los escenarios fueron utilizados para los 4 nodos simultáneamente. Los resultados se presentan en la tabla 36. Las primeras siete columnas de la tabla 36 tienen el mismo significado que en la tabla 35, y al final en la octava columna se pone el% de error que se presentó en cada nodo; las otras columnas no se ocupan, debido a que en esta evaluación todas los escenarios son utilizados para probar todos los nodos.

# Nodo	*# Escenarios*	*Detectados*	*Incorrecto*	*Falsos Positivos*	*Falsos Negativos*	*% Eficiencia*	*% Error*
3	24	16	1	5	2	66.67	33.33
9	24	18	2	4	0	75.0	25.0
10	24	19	3	0	2	79.17	20.83
13	24	24	0	0	0	100.0	0.0

Tabla 36: Evaluación 3 por nodo

Si se compara la Tabla 31 con la última aquí descrita 36, se puede observar de nuevo, que los valores de eficiencia son afectados significativamente, al igual que los porcentajes de error son bastante altos, sin embargo, al igual que en la Tabla 35, si viéramos el error general del modelo, observaríamos que es de un 4.0% (2 errores de detección en un nodo y 17 falsos positivos y negativos, en un total de 480 muestras), por lo que en una vista general el modelo funciona aceptablemente. En esta última evaluación, el desempeño general del modelo, presenta un 80.21% de eficiencia, mientras que el presentado en la Tabla 31 es de 94.79 %, mostrando que aunque la eficiencia decrementó, la detección de fallas por el modelo propuesto aún es aceptable.

Al analizar todo los datos, se puede decir que aunque la eficiencia se decrementó en todas las pruebas, como era de esperarse, el modelo sigue siendo un buen método para tratar con este tipo de redes, en donde hay muchos dispositivos, ruido y pérdida de información.

Cabe mencionar también, que en todos los modelos presentados anteriormente los datos continuos siempre deben de estar presentes, de lo contrario ninguna falla podrá ser identificada en el sistema; al contrario de los datos discretos, los cuáles al no estar presentes en la red, solamente degradan el desempeño de la red como se observó en esta última sección; esto es debido a que las TPC's de los nodos continuos tienen una densidad de probabilidad mayor que la de los nodos discretos, de manera que aunque haya ausencia de estos últimos, la red pueda seguir funcionando. Otra ventaja de haber desarrollado la RBH con probabilidades de menor peso en los datos discretos, es que al tener incertidumbre en los interruptores de protección, es decir, que éstos nos den lecturas erróneas, el modelo tendrá la capacidad de detectar correctamente el estado del nodo a través del valor del voltaje medido.

CAPÍTULO 8
Conclusiones

Este proyecto presentó un campo de detección de fallas para los sistemas industriales, basados en 2 etapas, en donde en la primera de ellas se acondicionan los datos para su correcto uso y en la segunda se hace el diagnóstico de la red. Aunque se presentaron diversos métodos estudiados durante la realización de la investigación, la aportación más importante para este campo estuvo basada en las redes bayesianas híbridas y las onduletas.

Nuestro enfoque utiliza dos teorías: la primera denominada teoría de onduletas, la cual analiza la información continua de la red de potencia, y extrae los rasgos característicos en patrones de coeficientes. Estos patrones, serán utilizados en la RBH. La segunda técnica es la RBH, la cual combina observaciones discretas de los componentes del sistema y los resultados de la aplicación de las onduletas en los datos continuos y determina el estado del nodo, y en el caso de que exista, el tipo de falla.

Los modelos aquí propuestos fueron probados en diversos escenarios de falla, en donde se presentaron resultados exitosos, e inclusive mejores que otros métodos ya propuestos, con un funcionamiento parecido al aquí utilizado. Las pruebas fueron realizadas en condiciones ideales y no ideales, siendo las primeras las que mayor éxito obtuvieron, como en un principio se pensó, debido a la carencia de ruido en los datos y la llegada de información correcta, sin embargo, aún en presencia de ruido e incertidumbre los resultados son satisfactorios. Cabe mencionar que el modelo es estático, por lo que no presenta la dinámica temporal.

8.1 Puntos fuertes del modelo

La propuesta aquí utilizada está enfocada a realizar el diagnóstico en sistemas con un número grande de observaciones o datos discretos o continuos, los cuáles en conjunto ayudan a aislar y detectar la falla que se presenta.

La técnica utilizada nos permite manejar un grado de incertidumbre alto, que nos permite la identificación de la falla aunque exista la presencia de ruido, datos erróneos o información faltante. Muchas otras técnicas no presentan estas ventajas, dando como resultado una gran limitación en el algoritmo utilizado para el diagnóstico de fallas.

Otro punto importante, es que el hecho de utilizar en una sola técnica, datos continuos y discretos, reduce el tiempo de cómputo en algunos casos y da resultados más eficaces, que si solo se hiciera un muestreo de las señales análogas.

Por último, el aspecto más importante de esta investigación y de esta propuesta, es que no se explotaron las características específicas del dominio, haciendo que la metodología que aquí se siguió sea muy flexible para diagnosticar sistemas en otros campos de aplicación.

8.2 Limitaciones

La mayor limitación que se puede observar en este modelo, es que es estático. Un modelo dinámico podría representar de una manera más real, un proceso industrial. Sin embargo, el modelo que aquí se presentó, puede ser modificado con el paso del tiempo, y su funcionamiento muy probablemente siga siendo bueno, aunque, se requerirá de cierto conocimiento para hacer estas actualizaciones.

La propuesta aquí presentada no es adecuada para algunas aplicaciones en sistemas que tengan muy pocas mediciones u observaciones, debido a que ésta basada en el historial de los datos.

8.3 Trabajo Futuro

Existen muchas maneras en que esta investigación puede ser mejorada y ampliada:

(a) Profundizar en el estudio de procesamiento de datos continuos para la creación de mejores índices de falla de los voltajes de los nodos, de manera que cada vez la firma de la señal sea la única que aparezca en los valores utilizados en el proceso de diagnóstico y se haga cada vez más insensible a la reacción en cadena que se tenga por motivo de errores en otros nodos.

(b) La expansión del último modelo aquí presentado, a una red que pueda degradarse con el tiempo, como lo haría una red eléctrica real debido a la fatiga y a las fallas presentadas en sus diversos dispositivos, es decir, convertir la RBH en una Red Bayesiana Dinámica-Híbrida, de manera que los modelos se presenten en ventanas temporales, y muestren la dinámica del cambio en las interrelaciones de los nodos eléctricos.

(c) Evaluación del décimo modelo en tiempo real. Se cree que al tener una extracción de rasgos característicos de los voltajes por medio de la primera descomposición de DWT, el tiempo de cómputo total será menor y por lo tanto el modelo de 2 etapas, sea un método atractivo para probarse en tiempo real.

(d) Posteriormente, se debe estudiar la aplicación del método aquí presentado a diversos procesos que se realicen en la industria, con el fin de probar la robustez del modelo, y para comprobar la hipótesis de que las RBH pueden ser aplicadas a cualquier campo de trabajo.

(e) Elaboración de las diferentes interfaces que comunicarán las dos etapas del modelo (procesamiento de datos y detección de fallas), para que pueda ser realizado en la menor cantidad de tiempo posible, por cualquier persona y pueda ser un programa factible para la detección de fallas en tiempo y procesos reales.

Apéndice A

Parámetros de la red de IEEE

Valores de Red				
Bus	Voltaje de Base	Carga		
Número	(kVolts)	Mwatts	Mvar	%
1	138	108	22	3.8
2	138	97	20	3.4
3	138	180	37	6.3
4	138	74	15	2.6
5	138	71	14	2.5
6	138	136	28	4.8
7	138	125	25	4.4
8	138	171	35	6.0
9	138	175	36	6.1
10	138	195	40	6.8
13	230	265	54	9.3
14	230	194	39	6.8
15	230	317	64	11.1
16	230	100	20	3.5
18	230	333	68	11.7
19	230	181	37	6.4
20	230	128	26	4.5

Tabla A 1: Cargas en la red de potencia de IEEE

Impedancias de línea			
del bus (#)	al bus (#)	Resistencia (Ω)	Inductancia (mH)
1	2	1.38	19.50
1	3	28.88	296.36
1	5	11.53	118.57
2	4	17.35	177.79
2	6	26.29	269.42
3	9	16.29	166.98
3	24	1.22	117.73
4	9	14.18	145.51
5	10	12.06	123.9
6	10	7.35	84.89
7	8	8.41	86.16
8	9	22.59	231.67
8	10	22.59	231.67
9	11	1.22	117.73
9	12	1.22	117.73
10	11	1.22	117.73
10	12	1.22	117.73
11	13	3.23	66.79
11	14	2.86	58.65
12	13	3.23	66.79
12	23	6.56	135.55
13	23	5.87	121.38
14	16	2.65	54.58
15	16	1.16	24.28
15	21	3.33	68.76
15	24	3.54	72.83
16	17	1.75	36.34
16	19	1.59	32.41
17	18	0.95	20.21
17	22	7.14	147.76
18	21	1.75	36.34
19	20	2.70	55.57
20	23	1.48	30.31
21	22	4.60	95.14

Tabla A 2: Impedancias de la red de potencia de la IEEE

Apéndice B

Medias y Varianzas de los nodos sin ser tratados

Número de nodo	Fase A		Fase B		Fase C	
	Media	Varianza	Media	Varianza	Media	Varianza
1	- 0.024714	7893.621584	0.013918	7895.9787	0.010798	7895.9894
2	- 0.026439	8566.3762	0.013201	8568.9729	0.013239	8568.9852
3	- 0.046799	15703.595	0.008219	15708.749	0.038492	15710.568
4	- 0.042322	12051.057	0.013516	12055.725	0.029368	12056.185
5	- 0.036838	10627.724	0.010195	10631.861	0.026912	10632.356
6	- 0.044694	12344.8	0.010986	12349.293	0.032880	12350.728
7	- 0.028957	10561.305	0.015021	10564.446	0.013849	10564.464
8	- 0.037583	12206.227	0.014852	12209.967	0.020784	12210.899
9	- 0.045902	15402.652	0.010325	15408.723	0.036599	15409.694
10	- 0.046140	14051.961	0.005122	14057.69	0.041487	14058.668
11	- 0.043290	17973.302	0.017891	17979.464	0.025700	17980.203
12	- 0.043705	17531.02	0.016753	17537.17	0.027344	17537.983
13	- 0.046308	26131.425	0.022064	26139.363	0.024322	26139.4
14	- 0.041509	21438.871	0.020876	21445.338	0.020646	21445.355
15	- 0.048565	28909.682	0.022842	28918.418	0.025619	28918.425
16	- 0.045689	25980.216	0.022829	25988.036	0.022855	25988.064
17	- 0.045906	26166.08	0.022515	26173.958	0.023333	26173.961
18	- 0.046059	26300.538	0.022340	26308.46	0.023624	26308.449
19	- 0.045025	24697.646	0.023116	24705.145	0.021907	24705.951
20	- 0.039797	22574.378	0.019474	22581.07	0.020327	22581.803
21	- 0.041262	21677.352	0.021727	21683.824	0.019531	21683.821
22	- 0.045622	25942.126	0.022636	25949.92	0.022985	25949.92
23	- 0.041317	21462.737	0.020834	21469.178	0.020490	21469.204
24	- 0.044711	20003.177	0.021118	20009.054	0.023788	20010.551

Tabla B 1: Media y varianza de los nodos de la red eléctrica industrial, sin ser tratados.

Apéndice C

Índices de Falla

Número de nodo	Índice normal	Índice de Falla									
		A-B	A-C	B-C	A-Gnd	B-Gnd	C-Gnd	AB-Gnd	AC-Gnd	BC-Gnd	ABC-Gnd
1	7.074697	6.947467	11.47697	7.241442	7.271375	7.037488	7.951017	7.138138	8.051015	7.816773	7.917646
2	7.611137	7.393054	12.13859	7.694123	7.726344	7.726344	8.438706	7.589244	8.543539	8.302436	8.406302
3	13.70147	24.11643	-5.44935	9.361226	16.79115	21.54029	4.899002	20.47915	5.758546	10.52255	9.465134
4	12.15576	21.89083	6.466778	12.2578	15.87724	18.62927	6.859311	18.73287	6.954977	9.714605	9.809882
5	10.78913	18.63041	0.810841	8.684753	13.32425	15.60717	6.218807	15.85229	6.444268	8.754492	8.980146
6	12.83426	23.63235	13.70864	12.35645	17.97701	19.29365	10.68587	20.98594	12.38424	13.77905	15.48863
7	8.192991	8.202878	12.69806	8.224141	12.73045	8.209018	8.751324	12.71774	13.26083	8.739151	13.24811
8	10.43116	18.01495	-3.55139	6.980554	12.17007	14.83429	3.791967	14.92997	3.873963	6.552899	6.634896
9	13.43652	23.79869	-4.32935	9.533416	16.76868	21.22494	1.087052	22.11311	6.250713	6.471943	11.62315
10	13.78622	25.6355	3.775213	11.45711	18.95933	21.4231	5.732712	23.70879	10.85592	13.39167	15.74014
11	12.10785	28.10863	-8.55917	6.229075	13.35555	18.56595	-2.80193	18.91105	-2.44822	2.776248	3.124908
12	12.31197	21.25897	-7.85443	6.597128	13.78787	18.85182	-2.30332	19.32252	-1.82015	3.261382	3.737739
13	12.65884	12.42455	20.03986	12.63017	19.7914	12.51933	13.72563	19.67525	20.87976	13.61181	20.76348
14	11.37058	11.12751	18.10942	11.36259	17.83519	11.2317	12.3816	17.70876	18.86148	12.25727	18.73497
15	13.22509	12.68874	21.5353	13.37364	13.34765	12.92761	14.75558	13.06587	14.89629	14.47605	14.61438
16	12.42266	20.17935	13.84602	12.9753	12.61789	13.83429	13.45815	14.03013	13.65341	14.86981	15.06685
17	12.49886	29.35806	-13.2912	4.692591	12.50232	18.76426	-5.9147	18.76807	-5.91093	0.351242	0.354963
18	12.54973	12.14057	20.32228	12.86272	12.66158	12.32822	13.90471	12.43901	14.01663	13.68311	13.79396
19	12.21578	20.40909	-12.5388	4.674914	12.15414	18.2634	-5.53721	18.20286	-5.59544	0.516641	5.533302
20	10.97805	18.85762	-12.2549	3.812307	10.86244	16.69994	-5.73979	16.58226	-5.8367	0.005894	4.544967
21	11.24195	10.82873	18.36237	11.35069	11.35283	11.01528	12.51719	11.12937	12.62881	12.29109	12.40524
22	12.41718	12.26986	19.6444	12.41586	19.51482	12.33713	13.40129	19.43337	20.49821	13.32111	20.4167
23	11.31843	11.12858	17.96627	11.31262	17.77059	11.2127	12.27003	17.67011	18.7297	12.17185	18.62951
24	12.2831	21.72997	-11.2518	5.927598	13.47683	19.54816	0.816426	19.57134	0.836076	6.911223	6.93102

Tabla C 1: Índices de Falla con método basado en [58].

Número de nodo	Índice normal	Índice de Falla									
		A-B	A-C	B-C	A-Gnd	B-Gnd	C-Gnd	AB-Gnd	AC-Gnd	BC-Gnd	ABC-Gnd
1	2.115233	2.389594	5.008997	2.579466	2.517466	3.302996	1.447293	3.489076	1.631065	2.41714	2.603633
2	2.562527	2.617556	5.2069	2.795128	2.762639	2.762639	1.521918	3.757422	1.718723	2.518162	2.714494
3	-19.9148	-27.6619	15.63084	19.38054	-26.0419	7.197837	-10.2055	-5.87208	-12.2315	20.992	7.916492
4	3.539432	3.645278	0.950172	-2.76583	4.578442	-13.3795	18.53949	-13.2325	18.69307	0.722801	0.883363
5	5.926178	6.02475	-1.77306	-9.8573	7.538829	-10.9217	14.39579	-10.4834	14.79402	-3.70419	-3.24273
6	-6.76224	0.893687	-2.08119	25.30486	-6.51297	11.28475	4.34123	9.697208	3.024592	20.78418	19.17028
7	2.429838	2.457885	4.346111	2.460944	11.23855	2.539963	1.524467	11.32086	10.30665	1.607881	10.38899
8	5.224114	7.287666	-1.79509	-1.53503	6.170665	-8.58148	18.52072	-8.46166	18.64396	3.868103	4.0095
9	5.460972	3.833377	-4.55782	-14.2971	7.608357	-31.7795	24.89661	-30.1377	21.07115	-12.98	-16.7131
10	8.830873	7.773532	0.909155	-11.0464	14.53943	-25.7595	22.11228	-20.9286	23.52333	-16.9413	-12.1547
11	6.282018	14.11041	-3.56612	3.582548	7.431642	-16.8314	31.50675	-16.1846	32.11455	7.828199	8.470387
12	4.587984	-2.02681	-13.6854	-36.21	4.536521	-41.895	6.450294	-41.1081	7.155277	-39.2843	-38.4974
13	-9.01854	-8.84717	-17.4916	-8.92235	-25.2565	-9.60595	-8.44733	-25.923	-24.7639	-9.1195	-25.4304
14	4.385926	4.341137	7.848284	4.367795	17.1395	5.131932	2.75542	17.90725	15.53533	3.527606	16.30322
15	4.209859	4.291203	9.041786	4.699786	4.428829	6.135002	2.392009	6.384297	2.646223	4.353192	4.602619
16	-7.28855	-10.5149	-8.65638	-8.79912	-7.70659	0.27171	-6.52976	-0.16368	-6.94903	1.017851	0.594761
17	5.750996	9.784812	-8.15895	-6.07491	5.75739	-27.8171	32.10469	-27.8105	32.11111	-1.46367	-1.45695
18	-9.27458	-9.14621	-19.3322	-10.666	-9.52328	-10.5924	-9.29138	-10.8354	-9.53788	-10.6075	-10.8507
19	6.983182	12.29824	-3.92261	8.753296	6.860778	-15.0193	37.02897	-15.137	36.90424	15.01939	6.309271
20	5.758636	9.816554	-4.67925	4.063574	5.522712	-18.1334	33.37144	-18.3345	33.11518	9.45065	1.558388
21	4.586276	4.527123	8.395793	4.789016	4.799589	5.878164	2.74701	6.096409	2.96248	4.04157	4.259925
22	-13.2704	-13.2127	-26.8906	-13.2622	-31.2552	-13.8106	-14.2139	-31.7914	-32.1959	-14.7535	-32.7322
23	4.63092	4.629522	9.455437	4.610104	16.59666	5.27323	3.759052	17.26009	15.75068	4.425959	16.41386
24	2.400586	1.11698	-5.92123	-13.349	2.767659	-36.1793	22.08638	-36.1537	22.11753	-16.8353	-16.8044

Tabla C 2: Índices de Falla con PSO.

Número de nodo	Fase	Índice normal	Índice de Falla									
			A-B	A-C	B-C	A-Gnd	B-Gnd	C-Gnd	AB-Gnd	AC-Gnd	BC-Gnd	ABC-Gnd
1	A	4.0011	3.852	3.8509	3.9709	3.7334	3.9709	3.9709	3.7334	3.7334	3.9709	3.7334
	B	3.9982	3.8482	3.9679	3.8424	3.9679	3.7302	3.9679	3.7302	3.9679	3.7302	3.7302
	C	3.998	3.968	3.849	3.8424	3.968	3.968	3.7301	3.968	3.7301	3.7301	3.7301
2	A	4.1681	4.0446	4.0435	4.1694	3.9201	4.1694	4.1694	3.9201	3.9201	4.1694	3.9201
	B	4.1648	4.0405	4.1661	4.0343	4.1661	3.9166	4.1661	3.9166	4.1661	3.9166	3.9166
	C	4.1653	4.1666	4.0416	4.0348	4.1666	4.1666	3.9169	4.1666	3.9169	3.9169	3.9169
3	A	5.639049	5.792688	5.790995	5.977164	5.611606	5.977161	5.977162	5.611608	5.611611	5.977167	5.611613
	B	5.63543	5.789032	5.973775	5.785976	5.973771	5.603285	5.97377	5.604453	5.973773	5.603287	5.604459
	C	5.642169	5.979739	5.791208	5.794656	5.979738	5.979735	5.608945	5.979742	5.608947	5.608946	5.608948
4	A	4.9406	4.9469	4.9459	5.1015	4.7952	5.1015	5.1015	4.7952	4.7952	5.1015	4.7952
	B	4.9384	4.9429	5.0976	4.9416	5.0976	4.7883	5.0976	4.7883	5.0976	4.7883	4.7883
	C	4.9432	5.1023	4.9459	4.9484	5.1023	5.1023	4.7916	5.1023	4.7916	4.7916	4.7916
5	A	4.6394	4.5659	4.5647	4.7022	4.4325	4.7022	4.7022	4.4324	4.4325	4.7022	4.4324
	B	4.6382	4.5628	4.6991	4.561	4.6991	4.4267	4.6991	4.4268	4.6991	4.4267	4.4267
	C	4.6419	4.7028	4.5642	4.5668	4.7028	4.7028	4.4297	4.7028	4.4297	4.4297	4.4297
6	A	4.9997	4.9146	4.914	5.0503	4.7823	5.0502	5.0503	4.7823	4.7823	5.0502	4.7823
	B	4.996	4.9123	5.0484	4.9112	5.0484	4.7774	5.0483	4.7774	5.0483	4.7774	4.7774
	C	5.0008	5.0511	4.9149	4.9164	5.051	5.0511	4.7801	5.051	4.7801	4.7801	4.7802
7	A	4.6281	4.4836	4.4824	4.622	4.3446	4.622	4.622	4.3446	4.3446	4.622	4.3446
	B	4.6245	4.4791	4.157	4.6184	4.6184	4.3417	4.6184	4.3417	4.6184	4.3417	4.3417
	C	4.6248	4.6187	4.4802	4.1571	4.6187	4.6187	4.3418	4.6187	4.3418	4.3418	4.3418
8	A	4.9732	4.9102	4.909	5.0603	4.7627	5.0603	5.0603	4.7627	4.7627	5.0603	4.7627
	B	4.9697	4.908	5.0588	4.9054	5.0588	4.7575	5.0588	4.7575	5.0588	4.7575	4.7575
	C	4.9746	5.0624	4.909	4.9115	5.0624	5.0624	4.7603	5.0624	4.7603	4.7603	4.7603
9	A	5.5859	5.7154	5.7139	5.8935	5.5405	5.8935	5.8935	5.5405	5.5405	5.8935	5.5405
	B	5.5831	5.7146	5.8933	5.7116	5.8933	5.5352	5.8933	5.5352	5.8933	5.5352	5.5352
	C	5.5872	5.8983	5.7163	5.7194	5.8983	5.8983	5.5377	5.8983	5.54	5.5377	5.54
10	A	5.3347	5.3859	5.845531	5.541651	5.233901	5.541641	5.541628	5.840039	5.84004	5.541651	5.840044
	B	5.3321	5.3841	5.893346	5.382622	5.54032	5.228715	5.540329	5.838678	5.893341	5.228696	5.838676
	C	5.3372	5.5432	5.865527	5.388556	5.54318	5.543185	5.230426	5.898286	5.84345	5.232067	5.843455
11	A	6.035	6.28925	6.289251	6.484013	6.101602	6.484011	6.484011	6.101602	6.1016	6.484009	6.1016
	B	6.0307	6.284662	6.479751	6.283301	6.479748	6.092223	6.47975	6.092227	6.479749	6.092225	6.092228
	C	6.0363	6.485031	6.28778	6.291423	6.485031	6.485028	6.094643	6.485029	6.094646	6.094646	6.094649
12	A	5.9598	6.2663	6.2646	6.4578	6.0782	6.4578	6.4578	6.0782	6.0782	6.4578	6.0782
	B	5.9559	6.2621	6.4541	6.2589	6.4541	6.0692	6.4541	6.0692	6.4541	6.0692	6.0692
	C	5.9616	6.4592	6.2635	6.267	6.4592	6.4592	6.0717	6.4592	6.0717	6.0717	6.0717
13	A	7.2799	7.07502	7.07502	7.2799	6.85567	7.2799	7.2799	6.85567	6.85567	7.2799	6.85567
	B	7.2739	7.06769	7.2739	6.85088	7.2739	6.85088	7.2739	6.85088	7.2739	6.85088	6.85088
	C	7.2751	7.2751	7.06988	6.85088	7.2751	7.2751	6.85164	7.2751	6.85164	6.85164	6.85164
14	A	6.5939	6.4036	6.4018	6.6012	6.205	6.6012	6.6012	6.205	6.205	6.6012	6.205
	B	6.5889	6.3973	6.5962	5.9373	6.5962	6.201	6.5962	6.201	6.5962	6.201	6.201
	C	6.5892	6.5964	6.3986	5.9372	6.5964	6.5964	6.201	6.5964	6.201	6.201	6.201
15	A	7.6571	7.4355	7.4334	7.6651	7.2065	7.6651	7.6651	7.2065	7.2065	7.6651	7.2065
	B	7.6509	7.4279	7.6589	7.4165	7.6589	7.2	7.6589	7.2	7.6589	7.2	7.2
	C	7.6519	7.6598	7.4299	7.4174	7.6598	7.6598	7.2005	7.6598	7.2005	7.2005	7.2005
16	A	7.2588	7.0398	7.0415	7.2593	6.8251	7.2593	7.2593	6.8251	6.8251	7.2593	6.8251
	B	7.2532	7.0343	7.2537	7.0363	7.2537	6.8184	7.2537	6.8184	7.2537	6.8184	6.8184
	C	7.2536	7.254	7.035	7.0366	7.254	7.254	6.8192	7.254	6.8192	6.8192	6.8192
17	A	7.2847	7.0626	7.063	7.2849	6.8492	7.2849	7.2849	6.8492	6.8492	7.2849	6.8492
	B	7.279	7.0568	7.2792	7.0553	7.2792	6.8377	7.2792	6.8377	7.2792	6.8377	6.8377
	C	7.2796	7.2797	7.0553	7.0596	7.2797	7.2797	6.8354	7.2797	6.8354	6.8354	6.8354
18	A	7.3034	7.0847	7.0827	7.3034	6.8666	7.3034	7.3034	6.8666	6.8666	7.3034	6.8666
	B	7.2976	7.0775	7.2976	7.0424	7.2976	6.8604	7.2976	6.8604	7.2976	6.8604	6.8604
	C	7.2983	7.2983	7.0431	7.0794	7.2983	7.2983	6.8607	7.2983	6.8607	6.8607	6.8607
19	A	7.0774	6.8649	6.8632	7.0787	6.6556	7.0787	7.0787	6.6556	6.6556	7.0787	6.6556
	B	7.0719	6.8594	7.0732	6.8559	7.0732	6.6445	7.0732	6.6445	7.0732	6.6445	6.6445
	C	7.0724	7.0737	6.8558	6.86	7.0737	7.0737	6.6422	7.0737	6.6422	6.6422	6.645
20	A	6.7663	6.5648	6.5632	6.7692	6.3648	6.7692	6.7692	6.3648	6.3648	6.7692	6.3648
	B	6.761	6.5595	6.7638	6.5563	6.7638	6.3544	6.7638	6.3544	6.7638	6.3544	6.3544
	C	6.7615	6.7643	6.5561	6.5601	6.7643	6.7643	6.3521	6.7643	6.3521	6.3521	6.3546
21	A	6.6305	6.432	6.4303	6.6306	6.2341	6.6306	6.6306	6.2341	6.2341	6.6306	6.2341
	B	6.6257	6.4259	6.6258	6.4161	6.6258	6.2288	6.6258	6.2288	6.6258	6.2288	6.2288
	C	6.6255	6.6256	6.4268	6.4159	6.6256	6.6256	6.2284	6.6256	6.2284	6.2284	6.2284
22	A	7.2535	7.0363	7.0343	7.2535	6.8181	7.2535	7.2535	6.8181	6.8181	7.2535	6.8181
	B	7.248	7.0294	7.248	6.5239	7.248	6.8137	7.248	6.8137	7.248	6.8137	6.8137
	C	7.2482	7.2482	7.0308	6.5238	7.2482	7.2482	6.8136	7.2482	6.8136	6.8136	6.8136
23	A	6.5976	6.4036	6.4018	6.6013	6.205	6.6013	6.6013	6.205	6.205	6.6013	6.205
	B	6.5926	6.3973	6.5962	5.9373	6.5962	6.2011	6.5962	6.2011	6.5962	6.2011	6.2011
	C	6.5928	6.5964	6.3985	5.9372	6.5964	6.5964	6.201	6.5964	6.201	6.201	6.201
24	A	6.3664	6.7783	6.7765	6.9918	6.5693	6.9918	6.9918	6.5693	6.5693	6.9918	6.5693
	B	6.3625	6.774	6.9874	6.7705	6.9874	6.5594	6.9874	6.5594	6.9874	6.5594	6.5594
	C	6.3667	6.9907	6.773	6.7772	6.9907	6.9907	6.5625	6.9907	6.5625	6.5625	6.5625

Tabla C 3: Índices de Falla con Teoría de Ondeletas.

Apéndice D

Escenarios de falla para la red eléctrica de la IEEE

# Simulación	# Fallas	# Prueba	Tipo de fallas en los nodos de prueba (nodos, tipo de falla)
1	1	1	14 A-C
2			9 C Gnd
3			3 A-B Gnd
4			7 B-C
5			4 B-C Gnd
6		2	15 A-B Gnd
7			7 A-B
8			6 C Gnd
9			19 A-C
10			8 C Gnd
11	2	1	11 A-C; 14 B-C
12			23 A-C Gnd; 7 A-B
13			5 A-B; 2 A-C
14			3 A-B; 19 B Gnd
15			21 A-C Gnd; 20 C Gnd
16		2	17 A-B Gnd; 6 A-B
17			10 A-B; 2 B-C Gnd
18			21 A-C Gnd; 8 B-C
19			4 B-C Gnd; 5 A-B Gnd
20			19 A-C Gnd; 7 A-C
21	3	1	3 B Gnd; 18 B-C; 1 A-B-C Gnd
22			{2, 5} B-C; 20 A Gnd
23			{11, 13} A-B; 24 A-B Gnd
24			15 A-B-C Gnd; 11 C Gnd; 16 A-B
25			14 A-C Gnd; 1 A-B Gnd; 21 B-C Gnd
26		2	8 C Gnd; 13 A-B Gnd; 12 A-C Gnd
27			19 A-C; 8 A-B-C Gnd; 22 A-B
28			{8, 24} B-C; 12 B Gnd
29			7 A Gnd; 20 B-C; 23 C Gnd
30			{4, 14} C Gnd; 14 C Gnd
31	4	1	7 A-B-C Gnd; 9 A-B; 12 C-Gnd; 17 A-C Gnd
32			2 A-B-C Gnd; 3 C Gnd; 7 A-C Gnd; 24 A Gnd
33			{8, 16} B-C Gnd; 9 B Gnd; 11 A Gnd
34			{5, 6, 14} B-C Gnd; 15 A-B Gnd
35			4 B Gnd; 9 A-C; 13 B-C; 23 A-B
36		2	23 A-B; 14 C Gnd; 15 B-C; 16 A-B-C Gnd
37			{4, 19} C Gnd; 2 A-C; 18 A-B
38			3 A Gnd; 5 B-C Gnd; 9 A-C Gnd; 14 A-B-C Gnd
39			{2, 17} A-C; 6 C Gnd; 12 B-C
40			{9, 17} A-B Gnd; 1 C Gnd; 6 B Gnd
41	5	1	2 A-C; 11 C Gnd; 12 A-B; 8 B-C; 21 A-B-C Gnd
42			{1, 24} A-B-C Gnd; 20 A-C; 14 B-C; 6 C Gnd
43			{21, 24} A-B-C Gnd; 8 A-C Gnd; 18 A-B; 4 B-C Gnd
44			{9, 20} B-C; 3 A-B; 6 A-C; 15 A Gnd
45			{5, 20} C Gnd; 16 A Gnd; 7 A-B-C Gnd; 2 A-C
46		2	14 A-B Gnd; 18 A-B; 24 B Gnd; 23 A-B-C Gnd; 10 B-C Gnd
47			{9, 16} B-C Gnd; {7, 10} B-C; 18 A-B
48			3 A-B; 19 A-C Gnd; 5 A-B-C Gnd; 10 A-C; 17 B Gnd
49			{2, 19} A-B Gnd; {14, 20} B-C Gnd; 23 A-C
50			7 A Gnd; 18 A-B Gnd; 6 B-C Gnd; 20 B-C; 2 A-B

Tabla D 1:Escenarios de Falla para la red eléctrica de la IEEE

# de Simulación	Tipo de falla en el nodo de prueba	Tipo de falla en los otros nodos (nodos, tipo de falla)
1	3 A-B Gnd	{4, 10, 14} A-B; 11 A-B-C Gnd
2	3 A-B	{1, 2, 23} A-B; 13 A-B Gnd
3	3 A-B	{8, 23} A-B; 2 A Gnd; 20 A-B Gnd
4	3 A Gnd	12 A-B Gnd
5	3 A Gnd	21 A-B; 2 A Gnd; 23 A-B Gnd
6	3 A-B-C Gnd	16 A-B-C Gnd
7	9 NO FAULT	3 A Gnd
8	9 B-C	2 B-C; 7 A-B-C Gnd; 17 A-B; 20 A-B Gnd
9	9 B-C	12 A-B; 19 A-B-C Gnd
10	9 B-C	15 B-C
11	9 A-B-C Gnd	{3, 7} A-B-C Gnd; 22 B-C
12	9 A-B-C Gnd	{13, 23} B-C
13	10 NO FAULT	6 B-C
14	10 A-B	{5, 15} A Gnd; 6 B-C; 17 A-B
15	10 A-B	8 A-B
16	10 B-C	{2, 9} A-B Gnd; 5 A-B; 6 B-C
17	10 B-C	5 B-C; 17 A Gnd
18	10 A Gnd	{3, 5} B-C; 2 A-B-C Gnd; 14 A-B Gnd
19	13 A-B Gnd	8 A Gnd; 20 A-B
20	13 A-B-C Gnd	11 B-C
21	13 B-C	17 A-B; 22 A-B-C Gnd
22	13 A Gnd	{20, 22} A-B-C Gnd
23	13 NO FAULT	{9, 15} A-B; 8 A-B-C Gnd; 14 A Gnd
24	13 A Gnd	{8, 23} A Gnd; 22 A-B; 16 A-B Gnd

Tabla D 2: Simulaciones de escenarios de falla para evaluación 1

# de Simulación	Tipo de falla en los nodos de prueba (nodos, tipo de falla)
1	3 A-B Gnd; {9, 10} A-B; 13 A-B-C Gnd
2	{3, 9, 10} A-B; 13 A-B Gnd
3	{3, 10} A-B; 9 B-C; 13 A-B Gnd
4	3 A Gnd; 9 A-B Gnd; {10, 13} NO FAULT
5	{3, 9} A Gnd; 10 A-B Gnd; 13 A-B
6	{3, 13} A-B-C Gnd; {9, 10} NO FAULT
7	3 A Gnd; {9, 10, 13} NO FAULT
8	{3, 9} B-C; 10 A-B Gnd; 13 A-B
9	3 NO FAULT; 9 B-C; 10 A-B; 13 A-B-C Gnd
10	{3, 10} NO FAULT; {9, 13} B-C
11	{3, 9, 10} A-B-C Gnd; 13 B-C
12	3 NO FAULT; 9 A-B-C Gnd; {10, 13} B-C
13	{3, 10, 13} NO FAULT; 9 B-C
14	{3, 9} A Gnd; {10, 13} A-B
15	{3, 10} A-B; {9, 13} NO FAULT
16	{3, 9} A-B Gnd; 10 B-C; 13 NO FAULT
17	{3, 10} B-C; 9 NO FAULT; 13 A Gnd
18	3 B-C; 9 A-B-C Gnd; 10 A Gnd; 13 NO FAULT
19	3 A Gnd; 9 NO FAULT; 10 A-B; 13 A-B Gnd
20	{3, 9} NO FAULT; 10 B-C; 13 A-B-C Gnd
21	3 A-B; 9 NO FAULT; 10 A-B-C Gnd; 13 B-C
22	3 NO FAULT; {9, 10} A-B-C Gnd; 13 A Gnd
23	3 A-B-C Gnd; {9, 13} A-B; 10 A Gnd
24	3 A Gnd; 9 A-B Gnd; {10, 13} A Gnd

Tabla D 3: Simulaciones de escenarios de falla para evaluación 2

Apéndice E

Algoritmo para optimización de valores mediante el PSO

Programación de lectura de archivos:

```
%function y = litcount(filename, literal)
% Search for number of string matches per line.

filename = input('Nombre del archivo que contiene los nombres de los archivos','s');
fid = fopen(filename, 'rt');
numnodos=24; numarch=0; Tinifalla=4010; Tfinfalla=4290; Tininorm=1; Tfinnorm=3990;
da=500; db=150; dc=350;
while feof(fid) == 0
  tline = fgetl(fid);
  numarch=numarch+1;
  %disp(tline);
  DF=load(tline);
  for i=1:numnodos
     inicio=3*i-1;
     faseA=DF(:,inicio); faseB=DF(:,inicio+1); faseC=DF(:,inicio+2);
     vrms=sqrt(faseA.^2+faseB.^2+faseC.^2);
     S=1-((da.*faseA+db.*faseB+dc.*faseC)/3);
      MediasF(i,numarch)=mean(vrms(Tinifalla:Tfinfalla));
      DesvF(i,numarch)=std(vrms(Tinifalla:Tfinfalla));
      MediasN(i,numarch)=mean(vrms(Tininorm:Tfinnorm));
      DesvN(i,numarch)=std(vrms(Tininorm:Tfinnorm));

%%%
```

Programación de Algoritmo PSO:

```
% La Función objetivo es
% max{ sumati(sumatj(Si-Sj)) }  i=1,..,9  j=i+1,...,10
% donde
%       S= 1- ((da*Va+db*Vb+dc*Vc)/3)

rand('state',sum(100*clock)); % resets it to a different state each time.

Nomarch=[
'Datos1F3.txt            ';
'Datos1F4.txt            ';
'Datos1F9.txt            ';
'Datos1F7.txt            ';
'Datos1F6.txt            ';
'Datos1F14.txt           ';
'Datos1F8.txt            ';
'Datos1F7v2.txt          ';
'Datos1F19.txt           ';
'Datos1F15.txt           ';
'Datos2F3-19.txt         ';
'Datos2F5-2.txt          ';
'Datos2F21-20.txt        ';
'Datos2F11-14.txt        ';
'Datos2F4-5.txt          ';
'Datos2F23-7.txt         ';
'Datos2F17-6.txt         ';
'Datos2F10-2.txt         ';
'Datos2F21-8.txt         ';
'Datos2F19-7.txt         ';
'Datos3F2-20-5.txt       ';
'Datos3F3-18-1.txt       ';
'Datos3F15-11-16.txt     ';
'Datos3F14-1-21.txt      ';
'Datos3F4-17-14.txt      ';
'Datos3F24-11-13.txt     ';
'Datos3F8-13-12.txt      ';
'Datos3F7-20-23.txt      ';
'Datos3F24-12-8.txt      ';
'Datos3F19-8-22.txt      ';
'Datos4F2-3-7-24.txt     ';
'Datos4F4-9-23-13.txt    ';
'Datos4F15-14-6-5.txt    ';
'Datos4F7-9-12-17.txt    ';
'Datos4F1-9-6-17.txt     ';
'Datos4F16-11-9-8.txt    ';
'Datos4F6-17-2-12.txt    ';
'Datos4F4-2-19-18.txt    ';
'Datos4F23-14-15-16.txt  ';
```

```
'Datos4F14-9-3-5.txt      ';
'Datos5F2-11-12-8-21.txt  ';
'Datos5F3-6-15-20-9.txt   ';
'Datos5F20-14-24-6-1.txt  ';
'Datos5F16-7-20-2-5.txt   ';
'Datos5F2-23-14-19-20.txt ';
'Datos5F24-8-18-4-21.txt  ';
'Datos5F7-18-6-20-2.txt   ';
'Datos5F3-19-5-10-17.txt  ';
'Datos5F16-9-7-10-18.txt  ';
'Datos5F14-18-24-23-10.txt';
   ];
NumArch=[0  0  35 24 0  0  22 0  0  0;
        0  0  0  45 0  18 31 47 12 21;
        40 22 31 1  0  0  0  11 0  0;
        0  32 25 0  0  2  0  0  0  0;
        0  0  44 15 0  33 48 12 0  21;
        0  35 5  0  0  33 0  17 42 0;
        28 0  0  0  31 0  34 8  20 4;
        0  0  7  0  46 36 30 0  0  19;
        0  36 3  35 40 49 0  34 32 42;
        0  0  0  0  0  50 0  18 48 49;
        36 0  23 0  0  0  0  26 14 0;
        0  29 34 0  27 0  0  41 0  37;
        0  0  0  27 0  0  0  26 0  32;
        0  0  25 50 24 33 40 0  6  14;
        42 0  0  10 0  0  23 0  0  39;
        44 0  0  0  0  36 39 23 0  0;
        0  48 0  17 25 0  0  0  37 0;
        0  0  0  47 0  0  0  38 0  22;
        0  11 38 45 20 0  0  0  9  0;
        21 0  13 0  0  45 0  0  43 28;
        0  0  0  0  13 24 41 0  0  0;
        0  0  0  0  0  0  0  30 0  0;
        0  0  28 0  16 0  50 32 45 0;
        31 50 0  26 0  0  46 0  0  29];

Ns=500;

Niter=100;
Npt=1000;
Nd=3;
xmin(1)=-100; xmax(1)=100;
xmin(2)=-100; xmax(2)=100;
xmin(3)=-100; xmax(4)=100;

c1=.1;
c2=.1;
w0=0.01;
wf=.1;
```

```
maxgloe=-100000;
x=zeros(Nd,Npt,Niter);
v=zeros(Nd,Npt,Niter);

vmax(1)=(xmax(1)-xmin(1))/2;
vmax(2)=(xmax(2)-xmin(2))/2;
vmax(3)=(xmax(3)-xmin(3))/2;

% calcula las posiciones y velocidades iniciales de cada partícula

      for p=1:Npt
         maxind(p)=-100000;
        for d=1:Nd
          r=rand();
          x(d,p,1)=xmin(d)+r*(xmax(d)-xmin(d));
          v(d,p,1)=vmax(d)*(2*r-1);
        end
      end

%Numnodo=9;
totnumnodos=24;

%for Numnodo=1:totnumnodos
   k=1;

Numnodo = input('Número de nodo> ');
numfallas=10;
Tinifalla=4001; Tfinfalla=4300;
Tininorm=1; Tfinnorm=4000;

   for kk=1:numfallas
     if(NumArch(Numnodo,kk) ~= 0)
       arch=Nomarch(NumArch(Numnodo,kk),:)
       DF=load(char(arch));
       inicio=3*Numnodo-1;
       faseA(:,kk)=DF(:,inicio);
       faseB(:,kk)=DF(:,inicio+1);
       faseC(:,kk)=DF(:,inicio+2);
     end
   end

Numnodo
while(k<Niter)
%-----------------------------------------------------
% Inicia la parte de Cálculo de la función Objetivo

for p=1:Npt
  da=x(1,p,k);
  db=x(2,p,k);
  dc=x(3,p,k);
```

```
  %da=500; db=150; dc=350;
  %da=1178; db=-1013; dc=-300;
   for kk=1:numfallas
      MediasFS(kk)=0;
     if(NumArch(Numnodo,kk) ~= 0)
      S=1-
((da.*faseA(Tinifalla:Tfinfalla,kk)+db.*faseB(Tinifalla:Tfinfalla,kk)+dc.*faseC(Tinifalla:Tfinfalla,
kk))/3);
      MediasFS(kk)=mean(S);
     end
   end

   acum(k,p)=0;
   for ii=1:numfallas-1
      for jj=ii+1:numfallas
         acum(k,p)=acum(k,p)+abs(MediasFS(ii)-MediasFS(jj));
      end
   end

 end

% Busca el máximo global de la función alcanzado por todas las partículas
%
    for p=1:Npt
      if(acum(k,p) > maxgloe)
%           k
%           p
         xglo(1)=x(1,p,k);
         xglo(2)=x(2,p,k);
         xglo(3)=x(3,p,k);
         maxgloe=acum(k,p);
         %pause
      end
% Busca el máximo de la función que cada partícula tiene
      if(k>1)
         for kk=1:k
          if(acum(kk,p) > maxind(p))
            xind(1,p)=x(1,p,kk);
            xind(2,p)=x(2,p,kk);
            xind(3,p)=x(3,p,kk);
            maxind(p)=acum(kk,p);
          end
         end
      else
         xind(1,p)=x(1,p,k);
         xind(2,p)=x(2,p,k);
         xind(3,p)=x(3,p,k);
         maxind(p)=acum(1,p);
      end
```

```
    end % del for p=1....

% calcula el valor del peso inercial
       w=wf-((wf-w0)*k/Niter);
%        w=0.005;
%actualiza las velocidades de cada partícula
 for p=1:Npt
    r1=rand(); r2=rand();

    for d=1:Nd
    xant(d,p,k)=x(d,p,k);
    vant(d,p,k)=v(d,p,k);
    v(d,p,k+1)=w*v(d,p,k)+c1*r1*(xind(d,p)-x(d,p,k))+c2*r2*(xglo(d)-x(d,p,k));
    if(v(d,p,k+1)>vmax(d))
     v(d,p,k+1)=vmax(d)*sign(v(d,p,k+1));
    end
    x(d,p,k+1)=xant(d,p,k)+v(d,p,k);
    end
 end
 k=k+1
 %maxgloe
end % while
Numnodo
xglo(1)
xglo(2)
xglo(3)
maxgloe
   D(Numnodo,1)=xglo(1);
   D(Numnodo,2)=xglo(2);
   D(Numnodo,3)=xglo(3);
   D(Numnodo,4)=maxgloe;

%end % for numnodos
 %-----------------------------------------------------
```

Apéndice F

Algoritmo para Extracción de Rasgos Característicos mediante Teoría de Onduletas

Programación para descomposición de ondeletas:

```
% Se cargan los vectores con los valores de las señales
s = DatosF;

k=1;

for j=1:12 %número de columnas de datos

   w = 'coif3';
      [c,l] = wavedec(s(:,j),1,w); % Se realiza solo la primera descomposición de s, utilizando coif3

% Se reconstruye los coeficientes aproximados y detallados en el nivel 1, utilizando la estructura
de descomposición de ondeleta [c, l]

   for i = 1:1
      A(i,:) = wrcoef('a',c,l,w,i);
      D(i,:) = wrcoef('d',c,l,w,i);
   end

   A1(k,:)=A(i,:);
   k=k+1;

end

abs1=zeros(12,1); % vector en donde estarán contenidos los coeficientes individuales de cada
muestra

for d=1:12 %número de columnas de datos
    for j=1:5000 %número de datos en cada columna, osea número de renglones
       abs1(d,1)=abs1(d,1)+abs(A1(d,j)); %se realiza la suma de los valores absolutos de los
coeficientes individuales de cada muestra
   end
end

abs1 %se despliega el resultado
```

Bibliografía

1. Dash S., Venkatasubramanian V.: "Challenges in the Industrial Applications of Fautl Dianostic Systems". Computers and Chemical Engineering, Vol. 24, 2000, pp. 785-791.

2. Garza L.; ”Hybrid Systems Fault Diagnosis with a Probabilistic Logic Reasoning Framework”. PhD Thesis. Presented to the Graduate Program in Computer, Information and Communication of the Instituto Tecnológico y de Estudios Superiores de Monterrey, Campus Monterrey. October 2001.

3. Zhao W.,Bai X., Ding J., Fhang Z., Li Z. and Zhou Z.; "A New uncertain Fault Diagnosis Approach of Power System Based Markov Chain Monte Carlo Method". International Conference on Power System Technology. 2006, pp. 1-6.

4. Elkalashy, Nagy I. ; Lehtonen, Matti; Tarhuni, Naser G.: ”DWT and Bayesian technique for enhancing earth fault protection in MVnetworks”, Power Systems Conference and Exposition, 2009. PSCE ’09. IEEE/PES, Power Syst.&High Voltage Eng., Helsinki Univ. of Technol., Helsinki. 23 April, 2009, pp. 1-5.

5. Penya, Yoseba K.; Bringas, Pablo G.; Zabala, Argoitz: ”Advanced fault prediction in high-precision foundry production”, 6th IEEE International Conference on Industrial Informatics, 2008. INDIN 2008, S3 Lab., Deusto Technol. Found., Bilbao. 03 September, 2008, pp. 1672-1677.

6. N’guessan, Kahan; Jouseau, Eric; Rognon, Jean-Pierre; Rostaing, Gilles; Francois, Florence: ”Joint faults detection in LV switchboard and its global diagnosis, through a Temperature Monitoring System”, International Conference on Power Engineering, Energy and Electrical Drives, 2007. POWERENG 2007, Laboratoire d’Electrotechnique de Grenoble, France; Schneider-Electric Services division. E-mail: kahan.nguessan@schneider-electric.com. 12 November, 2007, pp. 736-741.

7. Z.G. Tian; X.Y. Meng; H.F. Zhang: ”Application of Bayesian Theory in Fault Diagnosis of Turbo-generators”, 2005 IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific, Sch. of Marine Eng., Dalian Maritime University. 05 December, 2005, pp. 1-5.

8. Widarsson, B.; Karlsson, C.; Dahlquist, E.: ”Bayesian network for decision support on soot blowing superheaters in a biomass fuelled boiler”, 2004 International Conference on Probabilistic Methods Applied to Power Systems, Dept. of Public Technol., Malardalen Univ., Vasteras. 17 January, 2005, pp. 212-217.

9. Cho, Hyun Cheol; Knowles, Jeremy; Fadali, M. Sami; Lee, Kwon Soon: ”Fault Detection and Isolation of Induction Motors Using Recurrent Neural Networks and Dynamic Bayesian Modeling”, IEEE Transactions on Control Systems Technology, sponsored by IEEE Control Systems Society. 22 February, 2010, pp. 430-437.

10. Ahmed, Bilal; Young-Koo Lee; Sungyoung Lee: ”Detecting Faulty Percepts in a Context-Aware Ubiquitous System”, The 9th International Conference on Advanced Communication Technology, Dept. of Comput. Eng., Kyung Hee Univ., Seoul. 07 May, 2007, pp. 292-296.

11. Ali, Essam S.; Darwish, M.G.: ”Diagnosing network faults using bayesian and case-based reasoning techniques”, International Conference on Computer Engineering & Systems, 2007. ICCES ’07, Egyptian Air Force, Cairo. 07 February, 2008, pp. 145-150.

12. Jianguo Ding; Kramer, Bernd; Shihao Xu; Hansheng Chen; Yingcai Bai: ”Predictive fault management in the dynamic environment of IP networks”, Proceedings IEEEWorkshop on IP Operations and Management, 2004, Dept. of Comput. Sci. & Eng., Shanghai Jiao Tong Univ., China. 05 December, 2005, pp. 233-239.

13. Wakefield, N.H.; Bryant, K.P.J.; Knight, P.R.; Azzam, H.: ”FUMS TM artificial intelligence technologies including fuzzy logic for automatic decision making”, Annual Meeting of the North American Fuzzy Information Processing Society, 2005. NAFIPS 2005, Res. & Technol. Dev., Smiths Aerosp., Eastleigh, UK. 05 December, 2005, pp. 25-30.

14. Schwall, Matthew L.; Gerdes, J. Christian: ”A probabilistic approach to residual processing for vehicle fault detection”, Proceedings of the 2002 American Control Conference, 2002, Dept. of Mech. Eng., Stanford Univ., CA. 07 November, 2002.

15. Andersen, Morten N. ; Andersen, Rasmus O. ; Wheeler, Kevin: ”Filtering in hybrid dynamic Bayesian networks”, IEEE International Conference on Acoustics, Speech, and Signal Processing, 2004. Proceedings. (ICASSP ’04), Dept. of Informatics & Math. Modelling, Tech. Univ. Denmark, Lyngby, Denmark. 30 August, 2004.

16. Yunchun Li; Xianlong Qin; XiaoWang: ”Distributed Application Service Fault Management Using Bayesian Network”, Fifth International Conference on Natural Computation, 2009. ICNC ’09, Sch. of Comput. Sci. & Eng., Beihang Univ., Beijing, China. 24 December, 2009.

17. Lauber, Johannes; Steger, Christian; Weiss, Reinhold: ”Autonomous agents for online diagnosis of a safety-critical system based on probabilistic causal reasoning”, The Fourth International Symposium on Autonomous Decentralized Systems, 1999. Integration of Heterogeneous Systems. Proceedings, Inst. for Techn. Inf., Tech. Univ. Graz. 06 August, 2002.

18. Reece, Steven; Roberts, Stephen; Claxton, Christopher; Nicholson, David: ”Multi-sensor fault recovery in the presence of known and unknown fault types”, 12th International Conference on Information Fusion, 2009. FUSION ’09, Dept. Eng. Sci., Oxford Univ., Oxford, UK. 17 August, 2009.

19. Jafarian, Peyman and Sanaye-Pasand, Majid: ”A traveling-wave-based protection technique using wavelet/PCA Analysis”, IEEE Transactions on Power Delivery, Control and Intelligent Processing Center of Excellence, School of ECE, College of Engineering, University of Tehran, Tehran, Iran. Sponsored by IEEE Power & Energy Society. 01 February, 2010.

20. Shiroei, M.; Daniar, S.;Akhbari, M.: ”A New algorithm for Fault Location on Transmission Lines”,Sharif University of Technology, Tehran, Iran. 01 October, 2009.

21. Edachali, Dhilju Prakashan: ”Detection and signalling of high impedance faults in transmission line using fiber optic sensing network and PLC/SCADA technology”, 20th International Conference and Exhibition on Electricity Distribution 2009, India. 21 September, 2009.

22. Tian Shu; Ma Shishen: ”Traveling wave fault location in coal mine power transmission systems”, International Conference on Sustainable Power Generation and Supply, 2009. SUPERGEN ’09, Inst. of Electr. Eng. & Autom., Henan Polytech. Univ., Jiaozuo, China. 03 December, 2009.

23. Bo, Z.Q.; Han, M.; Klimek, A.; Zhang, B.H.; He, J.H.; Dong, X.Z.: ”A centralized protection scheme based on combined positional protection techniques”, IEEE Power & Energy Society General Meeting, 2009. PES ’09., AREVA T&D Autom., Stanford, UK. 01 October, 2009.

24. Ravindranath Reddy, B.; Vijaya Kumar, M.; Suryakalavathi, M.; Prasanth Babu, C.: ”Fault detection, classification and location on transmission lines using wavelet transform”, IEEE Conference on Electrical Insulation and Dielectric Phenomena, 2009. CEIDP ’09, Dept. of Electr. & Electron., JNT Univ., Hyderabad, India. 11 January, 2010.

25. Hua Lan; Tao Ai; Yang Li: ”Single Phase Adaptive Reclosure of Transmission Lines Based on EMD Approximate Entropy and LS-SVM with BCC”, International Conference on Information Engineering and Computer Science, 2009. ICIECS 2009, Electr. Eng. Inst., Northeast Dianli Univ., Jilin, China. 24 December, 2009.

26. Istrate, M.; Gusa, M.; Tibuliac, S.: ”Assessment of fault location algorithms in transmission grids”, 2009 IEEE Bucharest PowerTech, Dept. of Power Eng., Tech. Univ. Gheorghe Asachi of Iasi, Iasi, Romania. 08 October, 2009.

27. Youssef, Omar A.S.: ”An optimised fault classification technique based on Support-Vector-Machines”, Power Systems Conference and Exposition, 2009. PSCE ’09. IEEE/PES, Fac. of Ind. Educ., Suez Canal Univ., Suez. 23 April, 2009.

28. Geethanjali, M.; Priya, K. Sathiya: ”Combined wavelet transforms and neural network (WNN) based fault detection and classification in transmission lines”, 2009 International Conference on Control, Automation, Communication and Energy Conservation, 2009. INCACEC 2009, EEE Dept., Thiagarajar Coll. of Eng., Madurai, India. 17 August, 2009.

29. Valsan, Simi P.; Swarup, K. Shanti: ”High-Speed Fault Classification in Power Lines: Theory and FPGA-Based Implementation”, IEEE Transactions on Industrial Electronics, Dept. of Electr. Eng., Indian Inst. of Technol. Madras, Chennai. Sponsored by IEEE Industrial Electronics Society. 27 April 2009.

30. Kamel, T.S.; Hassan, Moustafa; El-Morshedy, A.: ”Using a combined Artificial Intelligent Approach in Distance Relay for Transmission line Protection in EPS”, Fifth International Conference on Soft Computing, Computing with Words and Perceptions in System Analysis, Decision and Control, 2009. ICSCCW 2009, Elec. Power & Machines Dept., Cairo Univ., Cairo, Egypt. 14 January, 2010.

31. Parikh, Umil B.; Biswarup Das; Prakash Maheshwari, Rudra Prakash: ”Combined Wavelet-SVM Technique for Fault Zone Detection in a Series Compensated Transmission Line”, IEEE Transactions on Power Delivery, Indian Inst. of Technol., Roorkee. Sponsored by IEEE Power & Energy Society. 23 September, 2008.

32. Khorashadi-Zadeh, Hassan; Zuyi Li: ”Transmission line distance protection using ANFIS and positive sequence components”, 2007 iREP Symposium Bulk Power System Dynamics and Control - VII. Revitalizing Operational Reliability, Illinois Inst. of Technol., Chicago. 26 December, 2007.

33. Kawady, Tamer A.; Ibrahim, Ayman E.; Taalab, Abdel-Maksoud: ”A Gabor Transform-based universal fault detector for transmission lines”, Electr. Eng. Department, Menoufiya University, Shebin El-Kom. 15 July, 2008.

34. He L.; "Application of Bayesian Network in Power Grid Fault Diagnosis". Fourth International Conference on Natural Computation. 2008, pp. 61-64.

35. Aravena Jorge L, Chowdhury Fahmida N. “A new Approach To Fast Fault Detection In Power Systems”. International Conference on Intelligent Systems Applications to Power Systems, 1996.

36. Mori, H. Aoyama, H. Yamanaka, T. Urano. “A hybrid intelligent system for fault detection in power Systems”. Proceedings of the 2002 International Joint Conference on Neural Networks. 2002.

37. Zhengyou He, Xian Wu, Qingquan Qian. “Automatic Fault Detection for Power System using Wavelet Singular Entropy”. Proceedings of the 2004 International Conference on Intelligent Mechatronics and Automation Chengdu, China. August 2004.

38. Douglas H., Pillay P. “The Application of Wavelets to shipboard Power system protection”. IEEE Electric Ship Technologies Symposium. 2005.

39. Samantaray S.R., Dash P. K., Panda G. “Transmission Line Fault Detection Using Time-Frequency Analysis”. IEEE Indicon 2005 Conference, Chennai, India, 11-13 Dec. 2005.

40. Rodríguez-Cortés Hugo, ,Stnkovic Aleksandar, Hadjicostis Christoforos N. “Model-Based Fault Detection in Power Systems”. IEEE ISIE 2006, July 9-12, Montréal, Québec, Canada.

41. Xu, L. and Chow, M.; "Power distribution systems fault case identification using logistic regression and artificial neural networks". Proceedings of the 13th Intl. Conf. on Intelligent Systems Application to Power Systems 2005, pp. 163-168.

42. Jing S., Shi-Yin Q., Yong-Hua S.: "Fault Diagnosis of Electric Power Systems based on Fuzzy Petri Nets". IEEE Transactions on Power Systems, Vol 19(4), November 2004, pp. 2053-2059.

43. Ren, H. and Mi, Z. "Power System Fault Diagnosis Modeling Techniques based on Encoded Petri Nets". International Conference on Power System Technology. 2006, pp. 1-6.

44. Lerner U., Parr R., Koller D., Biswas G. "Bayesian Fault Detection and Diagnosis in Dynamic Systems". 7th International Conferencie on Arti_cial Intelligence, 2000, pp. 531-537.

45. Charniak E.; "Bayesian Networks without Tears". AI Magazine, pp. 51-63.

46. Vekatasubramanian V., Rengaswamy R., Yin K., Kavuri S.:"A Review of Process Fault Detection and Diagnosis part I,II,III." Computers and Chemical Engineering, Vol. 27, pp. 293-346, 2003.

47. Software MICROTRAN, Micro Power Systems Analysys Corporation, http: www.microtran.com

48. Software HUGIN,Hugin Epert A/S, http:www.hugin.com

49. Riascos L., Cozman F. and Miyagi P.; "Bayesian Network Supervision on Fault Tolerant Fuel Cells". Escuela Polit_ecnica, Universidad de Sao Paulo. 2006 IEEE. Volume 2, pp. 1059-1066.

50. Jensen F.V.; "Bayesian Networks and Influence Diagrams". Aalborg University. Department of Mathematics and Computer Science. Denmark.

51. Lauritzen Steffen L., Wermuth N. "Graphical Models for Associations between variables, some of which are qualitative and some quantitavie". Aalborg University and University of Mainz. The Annals of Statistics, 1989, Vol. 17, No. 1, pp. 31-57.

52. Othman Mohd Fauzi, Amari Hudabiyah Arshad. "Online Fault Detection for Power System using Wavelet and PNN". 2nd. IEEE International Conference on Power and Energy (PECon 08), December 1-3, 2008, Johor Baharu, Malaysia.

53. Westlin SE, Bubenko JA. "Newton-Raphson technique applied to the fault location problem". IEEE PES Summer Meeting A76, 334-3; A976.

54. G.G. Richards, O.T. Tan. "An accurate fault location estimator for transmission lines". IEEE Trans Power Appar Syst PAS-101 4(1982), pp. 945-950.

55. M. Kezunoic. "A Survey of Neural Net Application to Protective Relaying and Fault Analysis", Eng. Int. Sys., Vol. 5, No. 4, Dec. 1997.

56. Walter H. Chung, Jason L. Speyer and Robert H. Chen. "A Decentralized Fault Detection Filter", ASME J. of Dynamic Systems, Measurement, Control, Vol. 123, 2001.

57. Sauhats Antans, Dolgicers Aleksandrs, Svalovs Andrejs. "Statistical approach based fault locating algorithms for power transmission lines". Proceedings of X Miedzynarodowa Konferencija Naukowa. Aktualine Problemy w Elektroenergetyce, Gdansk-Jurata, Poland, 2001, Vol. 2, pp. 233-238.

58. A. Sauhats, A. Jonins, V. Chuvychin, M. Danilova. “Fault location algorithms for power transmission lines based on Monte-Carlo Method”. Proceedings of IEEE Power Tech. Conference, Portugal, Porto, 2001, 5 p.

59. A. Sauhats, J. Gerhards, A. Mahnitko, A. Dolgicers. “Statistical Approach-based Fault Locating Algorithms for Power Transmission Lines”. Proceedings of I. Medzinarodne vedecke sympozium. EE2001 Elektroenergetika, Zbornik prednaok. Slovak Republic, Vysoke Tatry, 2001, pp. 221-224.

60. Vázquez-Martínez, Ernesto. “A travelling wave distance protection using principal component analysis”. International Journal of Electrical Power & Energy Systems Volume 25, Issue 6, July 2003, pp. 471-479.

61. Chanda D., Kishore N.K., Sinha A.K. “Application of Wavelet Multiresolution Analysis for Classification of Faults on Transmission Lines”. TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region.

62. Sanaye-Pasand, M; Malik, O.P; Zhihong Chen; Maun, J.-C. “Discussion of artificial neural network approach to single-ended fault locator for transmission lines”. IEEE Transactions on Power Systems. Dept. of Electr. & Comput. Eng., Calgary Univ., Alta. Volume 16, Issue 4, 2001, pp. 949-950.

63. G.K. Purushothama, A.N. Udupa, K. Parthasarathy, D. Thukaran. “Fault location on EHV Transmission Line for Network with Multiple Power Corridors”. Journal of Inst. Of Engineers (India), Vol. 81, 2000, pp. 62-29.

64. Y.H. Song, Q.X. Xuan, A.T. Johns. “Protection scheme for EHC transmission systems with thyristor controlled series compensation using radial basis function neural networks”. International Journal of Electric Machines and Power Systems, Vol. 25, No. 5, 1997, pp. 553-565.

65. K.H. Kim, J.K. Park, K.J. Hwang, S.H. Kim. “Implementation of Hybrid Short-term load forecasting system using artificial neural networks and fuzzy expert systems”. IEEE Transactions on Power System 10, 1995, Vol. 3, pp. 1534-1539.

66. S.M. Yeoa, C.H. Kim, K.S. Honga, Y.B. Limb, R.K. Aggarwalc, A.T. Johnsc, M.S. Choid. “A novel algorithm for fault classification in transmission lines using a combined adaptive network and fuzzy inference system”. International Journal of Electrical Power & Energy Systems. Volume 25, Issue 9, November 2003, pp. 747-758.

67. Albano M., Caldon R., Turri R. “Voltage SAG Analysis on Three Phase Systems Using Wavelet Transform and Probabilistic Neural Network”. 39 Intl. Universities Power Engineering Conference 2004. UPEC 2004. Vol. 3, pp. 948-952.

68. “Particle Swarm Optimization (PSO)”. Portal Scribd. http://www.scribd.com/doc/23247787/PSO-Particle-Swam-Optimization#stats.

69. Aravena, Jorge and Chowdhury, Fahmida. "A New Approach To Fast Fault Detection In Power Systems". Louisiana State University and Michigan Technological University, Electrical and Computer Enginering. 1996. IEEE.

70. He, Zhengyou; Wu, Xian and Qian, Qingquan. "Automatic Fault Detection for Power System using Wavelet Singular Entropy". School of Electrical Engineering, Southwest Jiaotong University, Chengdu, Sichuan Province, China. International Conference on Intelligent Mechatronics and Automation Chengdu, China, August 2004.

71. Douglas, H; Pillay, P.; Fellow, IEEE and Ortmeyer, T.H.; Fellow, IEEE. "The Application Of Wavelets to Shipboard Power System Protection". 2005, IEEE Electric Ship Technologies Symposium.

72. Othman, Mohd Fauzi and Amari, Hud Arshad. "Online Fault Detection for Power System using Wavelet and PNN". 2nd IEEE International Conference on Power and Energy (PECon 08), December 1-3, 2008, Johor Baharu, Malaysia.

73. Valens, Clemens. (Copyright C. Valens, 1999-2004). "A Really Friendly Guide to Wavelets". PolyValens. Recuperado el 1-Febrero-2010, de http://www.polyvalens.com/.

74. "Wavelets vs. Fourier Transforms". Last modified by Amara Graps on 12 May 2004. Copyright Amara Graps, 1995-2004. http://www.amara.com/IEEEwave/IW_wave_vs_four.html.

75. Pérez Enríquez, Román. "Wavelets (Ondeletas)". Centro de Geociencias, UNAM.

76. Polikar, Robi. "The Engineer's Ultimate Guide to Wavelet Analysis: The Wavelet Tutorial". Rowan University, College of Engineering Web Servers. March 07, 1999.

77. Sheng, Y. "Wavelet Transform". The transforms and applications handbook. Ed. By A.D. Poularikas. P. 747-827. Boca Raton, FI (USA): CRC Press, 1996. The Electrical Engineering Handbook Series.

78. Daubechies, I. "Ten Lectures on Wavelets". 2nd ed. Philadelphia: SIAM, 1992. CBMS-NSF Regional Conference series in applied mathematics 61.

79. Mallat, S.G. "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.11, No. 7 (1989), pp. 674-693.

80. "La transformada wavelet discreta". http://coco.ccu.uniovi.es/immed/compresion/descripcion/spiht/discreta/discreta.htm.

81. Garza L., Nieto J.P., Garza M., Morales R.; "Fault Diagnosis of Industrial Systems with Bayesian Networks and Neural Networks". Springer-Verlag Berlin Heidelberg, pp.998-1008, 2008.

82. Flores J., Garza L., Morales R., Nieto J., Ramírez R.; "Toward a New Fautl Diagnosis System for Electric Machines based on Bayesian Networks". American Control Conference 2005. USA, pp. 2775-2780.

83. Garza L., Acevedo S., Cantu F.: "Fault Diagnosis in Industrial Processes with a Hybrid Diagnostic System". Lecture Notes in Artificial Intelligence series: Lecture Notes in Computer Science. Germany. Pp. 536-546. April 2002.

84. Jing S., Shi-Yin Q., Yong-Hua S. "Fault Diagnosis of Electric Power Systems based on Fuzzy Petri Nets". IEEE Transactions on Power Systems, Vol. 19 (4), November 2004, pp. 2053-2059.

85. Nieto J., Garza L., Morales R.: "Multiple Fault Diagnosis in Electrical Power Systems with Probabilistic Networks". 6th Mexican International Conference on Artificial Intelligence (MICAI) 2007. México. November 2007, pp. 71-81.

86. Kourti T.; "Process Analysis and Abnormal Situation Detection: From Theory to Practice". IEEE Control System Magazine. October 2002.

87. Burrus, C.S. and R.A. Gopinath, H. Guo. "Introduction to wavelets and Wavelet Transforms, A Primer". Upper Saddle River, NJ (USA): Prentice Hall, 1998.