

# Detección y diagnóstico de fallas en sistemas eléctricos de potencia combinando una red neuronal autoasociativa y una red neuronal probabilística

Juan Pablo Nieto González

Universidad Autónoma de Coahuila, Facultad de Ingeniería  
Coahuila, México  
juan.nieto@uadec.edu.mx

**Resumen.** El monitoreo de los sistemas de potencia es particularmente retador debido a la presencia de cambios dinámicos de carga en modo de operación normal en los nodos de la red, presencia de variables continuas y discretas, información con presencia de ruido y falta o exceso de datos. Por ello, la necesidad de desarrollar metodologías más poderosas que combinen técnicas de inteligencia artificial ha sido reconocida. Este artículo propone un sistema de monitoreo basado en los datos históricos del sistema compuesto por dos fases. En la primera fase aprende el comportamiento de la operación normal del sistema utilizando una red neuronal autoasociativa (RNAA), la cual lleva a cabo el proceso de detección. En la segunda fase se da el diagnóstico final empleando una red neuronal probabilística (RNP), la cual clasifica el tipo de falla presente y proporciona su tiempo de ocurrencia.

**Palabras clave:** detección de fallas, diagnóstico de fallas, sistemas eléctricos de potencia, red neuronal autoasociativa, red neuronal probabilística.

## Fault Detection and Diagnosis in Electrical Power Systems Combining an Autoassociative Neural Network and a Probabilistic Neural Network

**Abstract.** Power systems monitoring is particularly challenging due to the presence of dynamic load changes in normal operation mode of network nodes, the presence of both continuous and discrete variables, noisy information and lack or excess of data. Due to this, the need to develop more powerful approaches combining artificial intelligence techniques has been recognized. This paper proposes a monitoring system based on the system history data composed by two phases. In the first phase it learns the normal operation behavior of the system using an autoassociative neural network (AANN) which carries out the detection process. In the second phase the final diagnosis is given using a probabilistic neural

network (PNN), which classifies the type of fault present and gives its time of occurrence.

**Keywords:** fault detection, fault diagnosis, electrical power systems, autoassociative neural network, probabilistic neural network.

## 1. Introducción

El monitoreo de los sistemas de ingeniería está relacionado a la detección y el diagnóstico de fallas. Primeramente se detectan patrones específicos de comportamiento en los datos observados y posteriormente se genera un diagnóstico completo del sistema.

Un moderno sistema eléctrico de potencia (SEP) es un ejemplo de tal sistema de ingeniería complejo. En él existen un gran número de sensores, controladores y módulos de cómputo que recolectan una gran cantidad de señales. Considerando que los modernos SEP, ya sean de una sola planta industrial, de una ciudad, región o país completo, son sistemas de gran escala. Y puesto que de ellos se puede extraer una gran cantidad de datos, es que se propone una metodología de monitoreo que emplea solamente datos históricos del proceso. Para llevar a cabo la detección y diagnóstico de fallas, en el presente artículo, se combina una red neuronal autoasociativa (RNAA) y una red neuronal probabilística (RNP). La metodología se aplica a un SEP de 24 nodos que contiene cambios dinámicos de carga propuesto por la IEEE mostrando resultados prometedores. La organización del artículo es la siguiente. La sección 2 revisa el estado del arte.

La sección 3 da los preliminares matemáticos de la RNAA y de la RNP. La sección 4 proporciona la descripción general de la propuesta. La sección 5 muestra un caso de estudio. Finalmente la sección 6 da la conclusión del artículo.

## 2. Estado del arte

Desde el punto de vista de seguridad y confiabilidad de los sistemas eléctricos, es necesario tener un oportuno diagnóstico de fallas. Lo anterior para poder detectar, aislar y diagnosticar fallas, así como dar aviso a los operadores del sistema para tomar las correspondientes acciones correctivas. Durante un disturbio, hay un gran número de eventos relacionados a las fallas, haciendo que el diagnóstico y la decisión de tomar acciones correctivas se torne una tarea difícil.

En este dominio, la necesidad de desarrollar técnicas más poderosas ha sido reconocida, y las técnicas híbridas que combinan varios métodos de razonamiento se han empezado a emplear. [1] considera la configuración de elementos automáticos en los modernos sistemas de potencia eléctrica, tales como relevadores de protección y de recierre automáticos para mejorar un modelo analítico y de optimización para el diagnóstico de fallas de sistemas de potencia. De acuerdo al principio de protección de los relevadores, el diagnóstico de fallas es expresado como un problema de programación entera y resuelto por el algoritmo genético de búsqueda Tabú. [2] presenta una metodología que utiliza redes neuronales

integradas con varias técnicas estadísticas. Entre las herramientas numéricas y estadísticas utiliza análisis de Fourier, valores RMS, valores de sesgo y de curtosis así como componentes simétricas para la detección y la identificación de las fallas es llevada a cabo mediante una red neuronal perceptrón multicapa. [3] propone un método compuesto de dos fases: En la primera fase una red neuronal probabilística es entrenada con los eigenvalores de los datos de voltaje obtenidos en operación normal así como con fallas simétricas y asimétricas. La segunda fase emplea una comparación entre las muestras para detectar y localizar la presencia de una falla. [4] utiliza lecturas de la corriente de fase solo durante el primer cuarto de ciclo empleando un método que combina componentes simétricas con un análisis de componentes principales para identificar y clasificar una falla. [5] propone una red bayesiana y minería de datos para diagnosticar fallas en una red eléctrica. El estatus de la información de las protecciones es tomado como atributos condicionales y la región de falla como un atributo de decisión. [6] propone una metodología capaz de localizar nodos de un sistema eléctrico en modo de falla. La metodología está compuesta por dos fases: en la primer fase una red neuronal probabilística se entrena con los eigenvalores de voltaje para dar una clasificación del tipo de falla presente. En la segunda fase se utiliza un ANFIS para dar el diagnóstico final. [7] se enfoca en el diseño de algoritmos de diagnóstico de fallas empleados como requisito para un control tolerante a fallas de un sistema eléctrico de distribución de energía. Emplea métodos basados en modelo y en particular utiliza relaciones analíticas redundantes para detectar cuando es que la red eléctrica ha tenido cambios dinámicos de carga. Este artículo emplea las ecuaciones básicas de la teoría de circuitos eléctricos y la topología de redes para llevar a cabo la detección de fallas y su correspondiente diagnóstico. [8] propone una metodología para la detección y diagnóstico de fallas de SEP utilizando un conjunto de rasgos característicos tiempo-frecuencia para la identificación, supervisión y detección de fallas en un controlador de flujo de potencia. La metodología extrae algunos rasgos característicos de una ventana de datos conteniendo un ciclo de la onda e incluye 3/16 de ciclo post falla empleando la transformada S rápida discreta ortonormal. Luego emplea una máquina de soporte vectorial para llevar a cabo la clasificación de las fallas. [9] muestra que la integración de sensores inteligentes para la detección y aislamiento de la falla en los SEP incrementa la resiliencia y robustez del control. Se monitorea el estado de los sensores sin emplear redundancia en el hardware. Propone un sensor que trabaja en tiempo real para la detección y aislamiento de fallas mediante el empleo de un algoritmo inteligente. La propuesta es probada en el sistema de 14 nodos propuesto por la IEEE. [10] propone una metodología de detección y clasificación de fallas en SEP utilizando el ángulo del factor de potencia. Los ángulos del voltaje y la corriente de los dos extremos de las líneas son comparados para realizar la detección y clasificación de las fallas. La técnica es aplicada al SEP de 15 nodos propuesto por la IEEE. [11] propone un sistema de detección y clasificación de fallas en SEP basado en el método de transformada wavelet empírica y la energía local. La transformada wavelet empírica es empleada para el proceso de detección y para la obtención del tiempo

de ocurrencia. Luego emplea una máquina de soporte vectorial para llevar a cabo la clasificación del tipo de falla basada en rasgos característicos de la energía local del sistema. [12] muestra una técnica descentralizada para la detección de fallas para SEP con puesta a tierra resonante. El propósito del artículo es detectar fallas de fase a tierra e identificar en que nodo sucedió dentro de los tres ciclos posteriores a la ocurrencia de la falla. Las fallas se detectan basandose en el desplazamiento del voltaje del neutro. Los voltajes de prefalla y post falla son utilizados para detectar la fase que se encuentra en modo de falla. Para identificar el nodo que se encuentra en modo de falla, se emplea una herramienta de procesamiento de señales llamada morfología matemática. La metodología se prueba en un SEP propuesto por la IEEE.

### 3. Preliminares

#### 3.1. Red neuronal autoasociativa (RNAA)

Nieto [6] propuso una RNAA utilizada como un método de Análisis de Componentes Principales No-Lineales (ACP NL) para identificar y remover correlaciones entre las variables de un problema como una ayuda para reducir la dimensionalidad, visualización de datos, y análisis exploratorio de datos.

ACP NL opera entrenando una red neuronal tipo feed-forward para llevar a cabo un mapeo idéntico de las entradas de la red y reproducirlas en la capa de salida. La red contiene una capa interna que actúa como un cuello de botella (la capa contiene una menor cantidad de neuronas que las capas de entrada o de salida), lo cual obliga a la red a desarrollar una representación compacta de los datos de entrada. La RNAA está compuesta por cinco capas. La Figura 1 muestra la arquitectura de la RNAA.

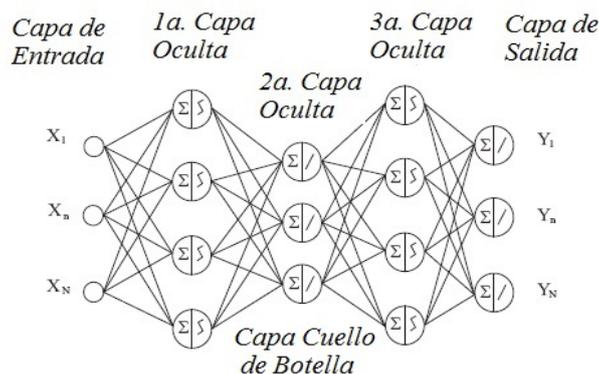


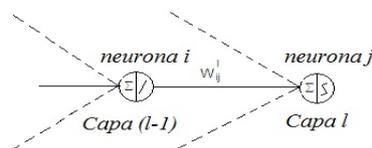
Fig. 1. Arquitectura de una RNAA.

Esta RNAA tiene una capa de entrada y una capa de salida, cada una con  $N$  neuronas y tres capas ocultas con  $H_1, H_2$ , y  $H_3$  neuronas respectivamente.

Cuando una observación  $x$  es presentada en la entrada de la red, la ecuación de la neurona de salida de la  $l^{th}$  capa es función de las neuronas en la  $(l-1)^{th}$  capa, dada por la ecuación 1 y mostrada en la Figura 2:

$$y_j = f\left(\sum_{i=1}^{n(l-1)} w_{i,j}^{(l)} y_i^{(l-1)}\right), \quad l = 1, \dots, 4, \quad (1)$$

donde  $y_j^{(0)} = x_n$ ,  $n = 1, \dots, N$  representa las componentes del vector de observaciones a la entrada de la red;  $y_n^{(4)}$ ,  $n = 1, \dots, N$ , representa las componentes de la estimación de  $x$  dada a la salida de la red;  $n(l-1)$  da el número de neuronas en la  $(l-1)^{th}$  capa. La función  $f(\cdot)$  es la función de activación de la neurona, la cual es sigmoideal. Las observaciones deben ser estandarizadas para que caigan dentro de un hipercono unitario.



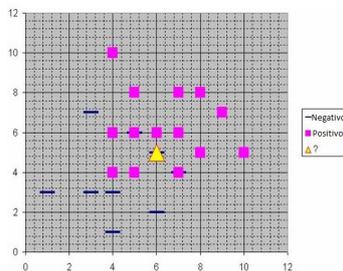
**Fig. 2.** Conexión de la  $i^{th}$  neurona de la  $(l-1)$  capa con la  $j^{th}$  neurona de la  $l$  capa.

Si la red tiene que aprender una tarea específica, es necesario ajustar los pesos de las conexiones entre las neuronas para minimizar la diferencia entre la salida esperada y la salida dada por la RNAA. Esta minimización es llevada a cabo cuando se calcula el error diferencial. El método más comunmente usado es el de retropropagación.

### 3.2. Red neuronal probabilística (RNP)

Las redes neuronales probabilísticas (RNP) son conceptualmente similares a los modelos de los  $K$  vecinos más cercanos ( $KNN$ ) por sus siglas en inglés. La idea básica se muestra en la Figura 3, la cual es que una variable es clasificada dentro de la clase a la que pertenezcan los  $K$  vecinos más cercanos de las variables predictoras. De la Figura 3 se asume que cada caso en el conjunto de entrenamiento tiene dos variables predictoras  $x$  y  $y$ . Los casos son graficados utilizando sus coordenadas  $x, y$  como se muestra en la figura.

También se asume que la variable objetivo tiene dos categorías, positiva la cual es denotada por un cuadrado y negativa, la cual es denotada por un guión. Puede notarse que el triángulo es posicionado casi exactamente sobre el guión, representando un valor negativo. Pero el guión se encuentra en una posición inusual comparado con los otros guiones, los cuales están agrupados por debajo de los cuadrados y a la izquierda del centro. Por lo anterior, parecería que el nuevo guión es un caso aislado. La clasificación de acuerdo al vecino más cercano



**Fig. 3.** Las RNP son conceptualmente similares a los  $K$  vecinos más cercanos.

dependerá de que tantos puntos en la vecindad sean considerados. Si se considera solamente un punto en la vecindad, se observa que el nuevo punto debería ser clasificado como negativo ya que se encuentra encima de un punto negativo conocido. Por otro lado, si se considera una clasificación empleando los 9 vecinos más cercanos, los 9 puntos más cercanos son considerados y entonces el efecto de los 8 puntos que rodean al punto nuevo lo clasificarán como un punto positivo.

Una red neuronal probabilística (RNP) se construye bajo este fundamento y se generaliza para considerar a todos los puntos presentes para la clasificación de una nueva observación. La distancia es calculada desde el punto siendo evaluado hacia cada uno de los otros puntos, y una función de base radial (FBR), también llamada función kernel es aplicada a la distancia para calcular el peso o influencia de cada uno de los puntos. La función de base radial es llamada así porque la distancia radial es el argumento de la función.  $Peso:FBR(distancia)$  por lo que mientras mas lejano se encuentre algún punto con respecto a la nueva observación, menos influencia tiene sobre ella. Se pueden emplear diferentes tipos de funciones de base radial, pero la mas común es la función *Gaussiana*. La arquitectura de la RNP se muestra en la figura 4. El modelo tiene dos capas: la capa de la base radial y la capa competitiva.

Hay  $Q$  pares de vectores de entrada/objetivo. Cada uno de los vectores objetivo tiene  $K$  elementos. Uno de estos elementos es 1 y el resto es 0. Así, cada vector de entrada esta asociado con una de las  $K$  clases. Cuando se presenta una entrada, el bloque  $||dist||$  produce un vector cuyos elementos indican que tan cerca se encuentra la entrada de los vectores del conjunto de entrenamiento. Un vector de entrada cercano a un vector de entrenamiento se representa por un numero cercano a 1 en la salida de  $a^1$ . Si una entrada esta cerca de varios vectores de entrada de una sola clase, ésta es representada por varios elementos de  $a^1$  cercanos a 1. Cada vector tiene un 1 solamente en el renglón asociado con la clase particular de la entrada y 0 en los demás elementos. La multiplicación  $Ta^1$  suma los elementos de  $a^1$  debidos a cada una de las  $K$  clases de entrada. Finalmente, la segunda capa, produce un 1 correspondiente al mayor elemento de  $n^2$  y 0 en cualquier otro elemento. Así, la red ha clasificado el vector de entrada dentro de una de las  $K$  clases debido a que esa clase tuvo la máxima probabilidad de ser la correcta.

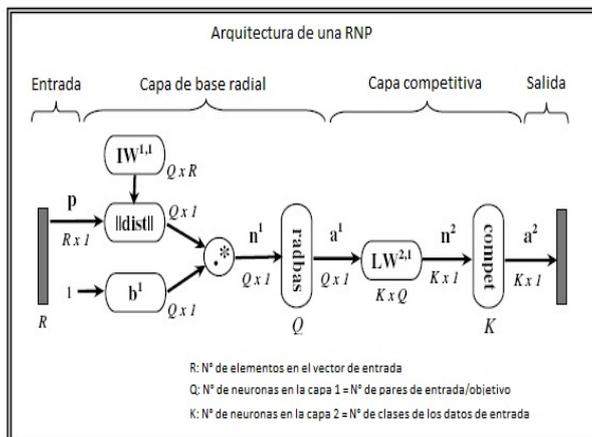


Fig. 4. Arquitectura de una RNP.

#### 4. Descripción de la propuesta

La presente propuesta es una metodología basada en el historial del proceso. Es necesario obtener bases de datos en modo de operación normal del SEP para entrenar una RNAA y así llevar a cabo el proceso de detección. Adicionalmente, se requieren bases de datos, que contengan información de las diferentes fallas que se pudieran presentar en el sistema que se monitorea. Las bases de datos de las posibles fallas se emplean para llevar a cabo el aprendizaje de la RNP. La cual se encarga de dar el diagnóstico final cuando el sistema se encuentra en modo de falla. El proceso general de entrenamiento para la fase de detección y para la de diagnóstico del sistema de monitoreo se muestra en la figura 5

El algoritmo para el proceso de entrenamiento se resume de la siguiente manera:

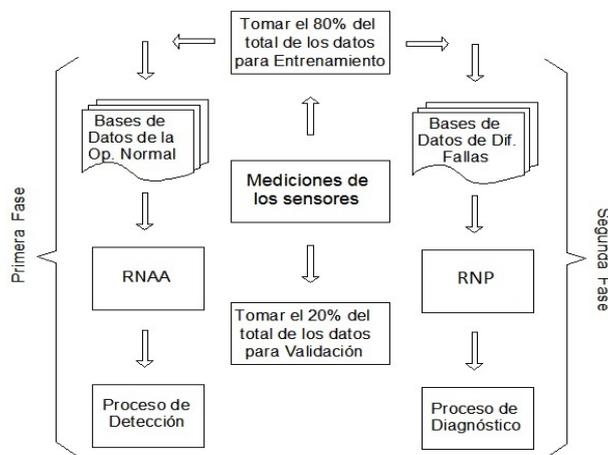
1. Localizar las mediciones provenientes de los sensores de las variables que se desean monitorear.
2. De manera aleatoria tomar un subconjunto ( $\approx 80\%$ ) de la cantidad total de datos para entrenar las herramientas de inteligencia artificial empleadas por la propuesta en la primera y segunda fase.

*Para la Primera Fase*

3. Tomar bases de datos de la operación normal del sistema.
4. Estandarizar el subconjunto de datos. Entrenar la RNAA y aprender el modelo.
5. Obtener los residuos de las condiciones de operación normal y sus correspondientes límites (umbrales).

*Para la Segunda Fase*

6. Tomar bases de datos de las diferentes fallas que pudieran presentarse en el sistema.



**Fig. 5.** Proceso general de entrenamiento para la fase de detección y la de diagnóstico del sistema de monitoreo.

7. Estandarizar el subconjunto de datos. Entrenar la RNP y aprender el modelo.
8. La RNP arroja el diagnóstico final.

Durante la primera fase del diagnóstico, el proceso de detección se lleva a cabo al obtener los residuos generados por la RNAA. Primeramente, se debe de realizar un proceso de estandarización para poder manipular las diferentes variables que se monitorean sobre una misma escala. Posteriormente se genera aleatoriamente un subconjunto de muestras formado por el 80 % del total de la base de datos. Dicho subconjunto de muestras es aprendido por la RNAA. Una RNAA de cinco capas, es una red cuyas salidas son entrenadas para emular las entradas sobre un adecuado rango dinámico. Esta característica de la red es muy importante para monitorear variables de sistemas complejos que presentan un cierto grado de correlación entre ellas, ya que cada salida recibe información de cada una de las entradas. Durante el entrenamiento, para hacer que cada salida iguale a su correspondiente entrada, las interrelaciones entre todas las variables de entrada y cada salida individual se refleja en los pesos de conexión de la red. Como resultado de lo anterior se tiene que cada salida específica e incluso la correspondiente salida, refleja solo una pequeña fracción del cambio de la entrada sobre un rango de valores razonablemente amplio. Ésto permite a la RNAA detectar la presencia de una falla, al comparar simplemente cada una de las entradas con su correspondiente salida, obteniendo de esta manera los residuos. Posteriormente se calculan los límites de dichos residuos para condiciones de operación normal del sistema.

Una vez que el proceso de detección es llevado a cabo, la segunda fase de la propuesta empieza a trabajar. Ésta utiliza la RNP para clasificar la falla presente previamente detectada por la primera fase. La salida de la RNP indica cual variable se encuentra en modo de falla, y el tiempo en el cual dicha falla ha

ocurrido. De esta manera, se proporciona un diagnóstico completo del sistema que se monitorea. La Figura 6 muestra el esquema general de operación en línea, del sistema de diagnóstico propuesto.

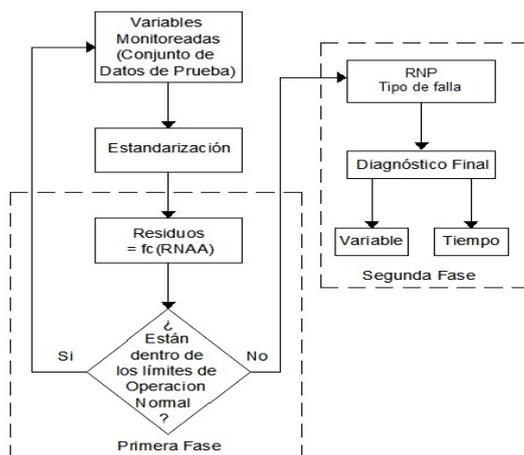


Fig. 6. Esquema de operación en línea del sistema de diagnóstico propuesto.

### 5. Caso de estudio

En esta sección se muestra el desempeño de la metodología propuesta. Para ello se lleva a cabo la simulación del SEP de 24 nodos propuesto por la *IEEE* y que presenta cambios dinámicos de carga. Tal SEP se muestra en la figura 7.

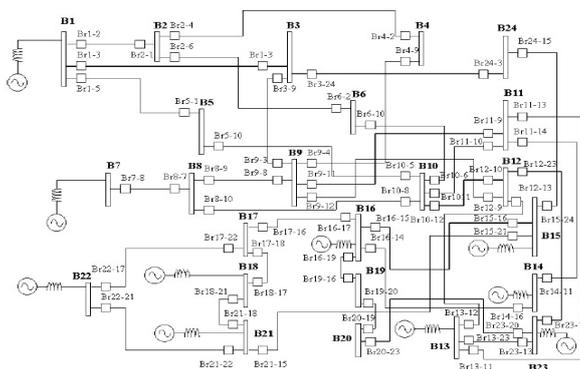


Fig. 7. Diagrama unifilar del SEP de 24 nodos propuesto por la IEEE.

El sistema de monitoreo propuesto se adecuó al caso de estudio como se muestra en el esquema de la figura 8 y se describe como sigue:

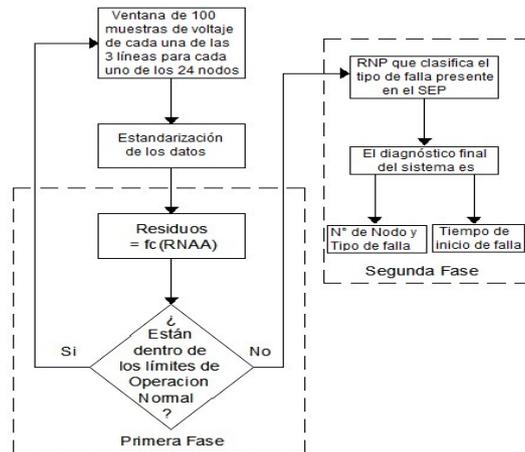


Fig. 8. Esquema de operación en línea del sistema de diagnóstico propuesto.

Se llevaron a cabo 24 simulaciones de falla para determinar el desempeño de la propuesta. Se incluyeron fallas simétricas y fallas asimétricas de forma aleatoria en los nodos 3, 9 10 y 13. Se tomaron en consideración diferentes escenarios y la presencia de múltiples fallas. Se combinaron fallas como: una línea a tierra (A GND), dos líneas a tierra (A-B GND), tres líneas a tierra (A-B-C GND) o fallas entre líneas (A-B o B-C) y el modo de no falla o modo de operación normal (NO FAULT).

La metodología propuesta se aplica como sigue:

1. Obtener ventanas de 100 muestras de los voltaje de cada una de las 3 líneas de los 24 nodos que conforman el SEP que se monitorea.
2. Estandarizar los valores.

*Primera Fase*

3. La salida de la RNAA muestra los residuos entre las entradas y salidas. Si los residuos están dentro de los límites de operación normal, regresar al paso 1. En caso contrario continuar con el paso 4.

*Segunda Fase*

4. La RNP clasifica sus entradas y en su salida arroja como diagnóstico final el número de nodo en el que está presente la falla, el tipo de falla presente y el tiempo en el cual da inicio el modo de falla.

En las siguientes tablas se muestra el desempeño de la propuesta tomando en cuenta 3 posibles casos:

**Caso 1.** El SEP trabaja adecuadamente durante las primeras 25 muestras del total de las 100 observaciones, es decir, 25 muestras están en modo de operación

normal y 75 en modo de falla.

**Caso 2.** Se toman 50 muestras en modo de operación normal y 50 en modo de falla.

**Caso 3.** Toma 75 muestras en modo de operación normal y 25 en modo de falla.

Las tablas 1 y 2 muestran un ejemplo de como fueron obtenidos los porcentajes. Las tablas 3 y 4 presentan un resumen de los porcentajes obtenidos para cada uno de los casos considerados.

**Tabla 1.** Detalle de desempeño en la detección y diagnóstico según el estado del nodo con 25 muestras en modo de operación normal y 75 con falla presente (caso 1).

| Estado del Nodo | Diagnóstico Correcto | Falsa Alarma | Precisión |
|-----------------|----------------------|--------------|-----------|
| A-B-C GND       | 14                   | 0            | 100 %     |
| A-B GND         | 10                   | 0            | 100 %     |
| A GND           | 14                   | 0            | 100 %     |
| A-B             | 16                   | 2            | 88.88 %   |
| B-C             | 14                   | 2            | 87.5 %    |
| SIN FALLA       | 17                   | 7            | 70.8 %    |

**Tabla 2.** Detalle de desempeño en la detección y diagnóstico por número de nodo con 25 muestras en modo de operación normal y 75 con falla presente (caso 1).

| Nodo Número | Diagnóstico Correcto | Falsa Alarma | Precisión |
|-------------|----------------------|--------------|-----------|
| 3           | 22                   | 2            | 91.66 %   |
| 9           | 20                   | 4            | 83.33 %   |
| 10          | 22                   | 2            | 91.66 %   |
| 13          | 20                   | 4            | 83.33 %   |

**Tabla 3.** Precisión en la detección y diagnóstico del estado del nodo para los diferentes casos

| Estado del Nodo | Caso 1  | Caso 2  | Caso 3  |
|-----------------|---------|---------|---------|
| A-B-C GND       | 100 %   | 100 %   | 100 %   |
| A-B GND         | 100 %   | 100 %   | 100 %   |
| A GND           | 100 %   | 85.71 % | 100 %   |
| A-B             | 88.88 % | 83.33 % | 77.77 % |
| B-C             | 87.5 %  | 87.5 %  | 75 %    |
| SIN FALLA       | 83.33 % | 83.33 % | 79.16 % |

Cabe mencionar que se llevaron a cabo varias pruebas con el total de las muestras en la ventana de datos en modo de operación normal y la metodología propuesta detectó el 100 % de las veces como nodos *SIN FALLA*.

**Tabla 4.** Precisión en la detección y diagnóstico por número de nodo para los diferentes casos.

| Estado del Nodo | Caso 1  | Caso 2 | Caso 3  |
|-----------------|---------|--------|---------|
| 3               | 91.66 % | 87.5 % | 83.33 % |
| 9               | 83.33 % | 87.5 % | 79.16 % |
| 10              | 91.66 % | 87.5 % | 83.33 % |
| 13              | 83.33 % | 87.5 % | 79.16 % |

### 5.1. Comparación contra dos sistemas de diagnóstico

Para observar el desempeño general, se llevo a cabo una comparación contra dos sistemas de diagnóstico similares. El primero de ellos es un sistema basado en lógica probabilística tomado de [13] y el otro es la propuesta de [3]. Las tablas 5 y 6 muestran el desempeño del sistema de diagnóstico basado en lógica probabilística. Las tablas 7 y 8 muestran el desempeño del sistema propuesto en [3].

**Tabla 5.** Desempeño en la detección y diagnóstico por nodo del sistema basado en lógica probabilística.

| Estado del Nodo | Correcto | Falsa Alarma | Precisión |
|-----------------|----------|--------------|-----------|
| A-B-C GND       | 14       | 0            | 100 %     |
| A-B GND         | 10       | 0            | 100 %     |
| A GND           | 12       | 2            | 85.7 %    |
| A-B             | 15       | 3            | 83.3 %    |
| B-C             | 16       | 0            | 100 %     |
| SIN FALLA       | 17       | 7            | 70.8 %    |

**Tabla 6.** Desempeño en la detección y diagnóstico por número de nodo del sistema basado en lógica probabilística

| Nodo Número | Diagnóstico Correcto | Falsa Alarma | Precisión |
|-------------|----------------------|--------------|-----------|
| 3           | 19                   | 5            | 79.1 %    |
| 9           | 21                   | 3            | 87.5 %    |
| 10          | 21                   | 3            | 87.5 %    |
| 13          | 23                   | 1            | 95.8 %    |

Comparando los resultados de las 3 propuestas, puede notarse que en general, las 3 tienen un desempeño muy similar. Si se compara el caso 1 de la propuesta del presente artículo contra el caso 1 de los otros dos artículos, se observa que la presente metodología tiene un mejor desempeño. Otro punto importante es que la nueva propuesta es relativamente más fácil de implementar y de actualizar cuando el SEP crece.

**Tabla 7.** Desempeño en la detección y diagnóstico por nodo del sistema utilizando la propuesta de [3].

| Estado del Nodo | Correcto | Falsa Alarma | Precisión |
|-----------------|----------|--------------|-----------|
| A-B-C GND       | 14       | 0            | 100 %     |
| A-B GND         | 10       | 0            | 100 %     |
| A GND           | 14       | 0            | 100 %     |
| A-B             | 18       | 0            | 100 %     |
| B-C             | 16       | 0            | 100 %     |
| SIN FALLA       | 13       | 11           | 54.16 %   |

**Tabla 8.** Desempeño en la detección y diagnóstico por número de nodo del sistema utilizando la propuesta de [3].

| Nodo Número | Diagnóstico Correcto | Falsa Alarma | Precisión |
|-------------|----------------------|--------------|-----------|
| 3           | 20                   | 4            | 83.33 %   |
| 9           | 19                   | 5            | 79.16 %   |
| 10          | 22                   | 2            | 91.66 %   |
| 13          | 24                   | 0            | 100 %     |

## 6. Conclusión

El artículo presenta una metodología de un sistema de monitoreo para la detección y diagnóstico de fallas en SEP con cambios de carga dinámica. La propuesta, se basa en los datos históricos del sistema por monitorear. Lo anterior es debido a que en la práctica tales datos son relativamente fácil de obtener ya que en la actualidad los sistemas complejos contienen al menos una computadora para su control, la cual almacena el comportamiento diario de éstos.

Una ventaja sobre los métodos basados en modelo, es que esta metodología necesita los datos históricos del sistema o proceso en modo de operación normal, y de las posibles fallas que se puedan presentar.

La metodología esta compuesta por 2 fases. En la primera fase se lleva a cabo el proceso de detección de falla presente en el sistema empleando una RNAA. Se emplea esta red, porque tiene la peculiaridad de que sus salidas siguen a sus entradas. De esta manera se pueden obtener los límites de operación normal, así como los residuos correspondientes entre sus salidas y entradas. Logrando así llevar a cabo el proceso de detección.

Una vez detectada una falla se pasa a una segunda fase compuesta por una RNP. Es en esta segunda fase dónde la RNP clasifica el tipo de falla presente en el sistema. Arrojando como diagnóstico final el número del nodo que se encuentra en modo de falla, el tipo de falla presente en éste nodo y el tiempo en cual inicia. Se decidió el empleo de una RNAA por la facilidad de obtener los residuos y lograr así la detección de la falla y la RNP para el diagnóstico debido a que este tipo de red neuronal presenta un buen desempeño al trabajar con problemas de clasificación. Adicionalmente, el empleo de estos 2 tipos de redes ofrece la ventaja de que necesitan poco tiempo para su entrenamiento.

## Referencias

1. Liao, Z., Wen, F., Guo, W., He, X., Jiang, W., Dong, T., Liang, J., Xu, B.: An Analytical Model and Optimization Technique Based Methods For Fault Diagnosis in Power Systems. In: IEEE Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, Nanjing, China, pp. 1388–1393 (2008)
2. Flauzino, R.A., Ziolkowski, V., da Silva, I.N., de Souza, D.M.B.: Hybrid Intelligent Architecture for Fault Identification in Power Distribution Systems. In: PES'09, IEEE Power & Energy Society General Meeting, pp. 1–6 (2009)
3. Nieto, J.P., Garza, L.E., Morales, R.: Multiple Fault Diagnosis in Electrical Power Systems with Dynamic Load Changes Using Probabilistic Neural Networks. *Computación y Sistemas*, vol. 14, no. 1, pp. 17–30 (2010)
4. Alsafasfeh, Q., Abdel-Qader, I., Harb, A.: Symmetrical Pattern and PCA Based Framework for Fault Detection and Classification in Power Systems. In: Conference on Electro Information Technology, pp. 1–5 (2010)
5. Qianwen, N., Youyuan, W.: An Augmented Naive Bayesian Power Network Fault Diagnosis Method based on Data Mining. In: Asia-Pacific Power and Energy Engineering Conference (APPEEC), pp. 1–4 (2011)
6. Nieto, J.P.: Multiple Fault Diagnosis in Electrical Power Systems with Dynamic Load Changes Using Soft Computing. In: 11th Mexican International Conference on Artificial Intelligence, MICAI 2012, San Luis Potosi, Mexico, vol. 2, pp. 319–330 (2012)
7. Knuppel, T., Blanke, M.: Fault diagnosis for electrical distribution systems using structural analysis. *International Journal of Robust and Nonlinear Control*, vol. 24, issue 8-9, pp 1446–1465, Special Issue: Fault Tolerant Control Power of Grids (2014)
8. Moravej, Z., Pazoki, M.: New Pattern-Recognition Method for Fault Analysis in Transmission Line With UPFC. *IEEE Transactions on Power Delivery*, vol. 30, issue 3, pp. 1231–1242 (2015)
9. Yang, H., Touria, E., Edrington, C.: Real-time sensor fault detection and isolation in power system with hardware implementation. In: North American Power Symposium (NAPS), Denver, CO, USA (2016)
10. Heydari, O., Khodabakhshi-Javinani, N., Askarian-Abyaneh, H.: A novel technique in detection and classification of faults using power factor angle. In: Conference on Electrical Power Distribution Networks Conference (EPDC), Semnan, Iran (2017)
11. Huang, N., Qi, J., Li, F., Yang, D., Cai, G., Huang, G., Zheng, J., Li, Z.: Short-Circuit Fault Detection and Classification Using Empirical Wavelet Transform and Local Energy for Electric Transmission Line. *Journal of Sensors*, vol. 17, issue 9, pp. 2133–2145 (2017)
12. Barik, Md. A., Gargoom, A., Mahmud, Md. A., Haque, Md. E., Al-Khalidi, H., Maung, A.: A Decentralized Fault Detection Technique for Detecting Single Phase to Ground Faults in Power Distribution Systems With Resonant Grounding. *IEEE Transactions on Power Delivery*, vol. 33, issue 5, pp. 2462–2473 (2018)
13. Garza, L.: Hybrid Systems Fault Diagnosis with a Probabilistic Logic Reasoning Framework. PhD Thesis (2001)