

# Avances en el diagnóstico de fallas en sistemas eléctricos de transporte mediante redes neuronales: Un enfoque modular

**Agustin Flores - Novelo**

**Eduardo Quiles - Cucarrella**

**Emilio García - Moreno**

**Francisco Morant - Anglada**

**Recibido: Mayo 2011**

**Aprobado: Junio 2011**

## RESUMEN

En este trabajo se propone un nuevo método para el diagnóstico de fallas en sistemas eléctricos de potencia basado en módulos neuronales. El método realiza el diagnóstico mediante la asignación de un módulo neuronal genérico para cada tipo de componente que conforma al sistema eléctrico de potencia, ya sea línea de transporte, bus o transformador. En total se diseñan tres módulos neuronales genéricos, uno para cada tipo de componente. Los módulos neuronales para buses y transformadores se componen de dos niveles de diagnóstico tomando en cuenta los estados lógicos de interruptores y relevadores tanto propios como de respaldo, a excepción del módulo neuronal para líneas de transporte, que además de los dos niveles de diagnóstico con los que cuentan los módulos neuronales para buses y transformadores, cuenta con un tercer nivel de diagnóstico que toma en consideración los oscilogramas de voltajes y corrientes de falla, así como los espectros de frecuencia de estos oscilogramas, para verificar si la línea de transporte realmente estuvo sujeta a una falla y a la vez determinar el tipo de ésta (L-g, LL-g, LL, LLL, LLL-g), esto a través de una estructura neuronal. Este tercer nivel de diagnóstico, es posible llevarlo a cabo ya que toda línea de transporte que es sometida a una falla presentará corrientes y voltajes de falla, antes de que ésta sea liberada del sistema por la acción de sus esquemas de protección.

Palabras claves: Redes neuronales modulares, diagnóstico de fallas, voltajes de falla, corrientes de falla, espectros de frecuencia de voltajes de falla, espectros de frecuencia de corrientes de falla.

## ABSTRACT

*This work proposes a new method for fault diagnosis in electric power systems based on neural modules. With this method the diagnosis is performed by assigning a generic neural module for each type of element within the electric power system, whether it is a transmission line, bus or transformer. A total of three generic neural modules are designed, one for each type of element. The neural modules for buses and transformers comprise two diagnostic levels that take into consideration the logic states of switches*

Agustin Flores-Novelo, Eduardo Quiles-Cucarella, Emilio García-Moreno, Francisco Morant-Anglada

*and relays, both internal and back up; the neural module for transmission lines, however, also has a third diagnostic level which takes into account waveforms of fault voltages and currents, as well as the frequency spectrums of these waveforms in order to verify if the line had in fact been subjected to a fault, and at the same time to determine which type of fault (L-g, LL-g, LL, LLL, LLL-g), by means of a neural structure. This third diagnostic level can be carried out given the fact that every transportation line subjected to a fault will present fault currents and voltages before the fault is eliminated from the system by the intervention of its protection systems.*

*Key words: Modular neural network, fault diagnosis, fault voltages, fault currents, spectrum of fault voltages, spectrum of fault currents.*

## INTRODUCCIÓN

En la actualidad los operadores de centros de control de los sistemas de transporte de energía eléctrica, se ven más abrumados por la gran cantidad de información que en su momento requieren analizar, para mantener en condiciones óptimas de operación al sistema. Cuando ocurre un evento en el sistema, en base a las alarmas proporcionadas por el SCADA y los componentes fallados, el operador trata de hacer un diagnóstico lo más aproximado del estado actual del sistema con la finalidad de restablecerlo lo más pronto posible, dicho diagnóstico se puede hacer extremadamente complicado dependiendo del número de componentes fallados y dispositivos de protección operados. El presente trabajo tiene como objetivo fundamental presentar la metodología para implementar un sistema de diagnóstico de fallas mediante la aplicación de redes neuronales artificiales con un enfoque modular a sistemas de transporte de energía eléctrica para ser utilizado como herramienta auxiliar en la toma de decisiones por los operadores de las áreas de control. Es bien sabido que el diagnóstico rápido y preciso ayuda a restablecer lo más pronto posible al sistema eléctrico colapsado.

En las últimas décadas se han desarrollado trabajos enfocados al diagnóstico de fallas en los sistemas eléctricos de potencia con diferentes estructuras neuronales tales como redes bayesianas<sup>1</sup>, redes de funciones de base radial (RBF)<sup>2 4</sup>, redes backpropagation<sup>10 22</sup>, redes SOM<sup>15</sup>, dando buenos resultados pero presentando limitaciones. Una de las limitaciones es la estructura cerrada de tipo monolítico que presentan las redes, de forma tal que cuando se aplican a sistemas eléctricos reales de gran tamaño se empieza a hacer más complicado implementarlas<sup>3 5 6</sup>.

El método de diagnóstico de fallas propuesto se compone de dos niveles de diagnóstico para los módulos neuronales de buses, líneas de transporte y transformadores, y de un tercer nivel para el módulo neuronal de las líneas de transporte. El primer nivel de diagnóstico verifica si la falla fue en el componente bajo análisis, mediante la operación correcta de los interruptores propios y/o de respaldo, asociados a éste<sup>16</sup>. El segundo nivel de diagnóstico verifica si la falla fue en el componente bajo análisis mediante la operación correcta de los esquemas de protección propios y/o de respaldo de éste<sup>16</sup>. Con el resultado de los dos niveles de diagnóstico previamente establecidos, se verifica que ambos niveles resulten verdaderos para que la falla sea asignada al componente bajo análisis, de lo contrario la falla no corresponderá a éste. El tercer nivel de diagnóstico asignado únicamente al módulo neuronal de las líneas de transporte, refuerza el diagnóstico de los dos primeros niveles, mediante el procesamiento de las señales continuas y espectros de frecuencia, de los oscilogramas de voltajes y corrientes de falla de la línea correspondiente, a través de una estructura neuronal, para verificar si realmente estuvo sujeta a una falla y a la vez determinar el tipo de ésta (L-g, LL-g, LL, LLL, LLL-g). Este proceso se puede llevar a cabo ya que toda línea de transporte que es sometida a una falla presentará corrientes y voltajes de falla, antes de que ésta sea aislada del sistema por sus respectivos esquemas de protección. Se demuestra que es posible obtener un sistema de diagnóstico de fallas más confiable y preciso para las líneas de transporte, si el resultado de la validación final obtenido de la combinación de las señales discretas de interruptores y dispositivos de protección, es reforzado, mediante el procesamiento de las señales continuas y espectros de frecuencia de los oscilogramas de voltajes y corrientes de falla, correspondientes a cada una de las líneas.

Una serie de trabajos relacionados con el diagnóstico de fallos en los sistemas de transporte de energía eléctrica, que utilizan a las redes neuronales artificiales como núcleo de diseño, y las limitaciones que estos presentan en su aplicación práctica como sistemas de diagnóstico se presenta a continuación:

Jiang Huilan, Guan Ying<sup>4</sup>, proponen una estructura neuronal del tipo función de base radial (RBF) para el diagnóstico de una línea de transporte, haciéndose más complicado el diagnóstico conforme el sistema aumenta en tamaño.

Tianshu Bi, Yixin Ni<sup>13</sup>, también ocupan una estructura neuronal del tipo RBF, la cual es entrenada de nuevo, si las muestras de entrenamiento son afectadas por cambios en la topología de la red o expansión de ésta.

Yann-CHang Huang<sup>12</sup>, ocupa estructuras neuronales del tipo ART (Teoría de Resonancia Adaptiva), aplicándolas a un sistema eléctrico de potencia con 12 buses, 8 líneas de transporte, 8 transformadores y 84 relevadores de protección. Presenta casos de estudio para fallos triples y cuádruples con un interruptor fallado simultáneamente, debido a que utiliza una red monolítica la degradación en el diagnóstico se hace mayor conforme la red eléctrica aumenta en tamaño.

M. Sanaye-Pasand, H. Khorashadi-Zadeh <sup>22</sup>, Tahar Bouthiba <sup>19</sup>, presentan un nuevo enfoque al utilizar señales analógicas de corrientes y voltajes de fallo muestreadas en un cierto intervalo de tiempo como patrones de entrenamiento para la estructura neuronal, con miras a detectar el componente fallado y el tipo de fallo a la que éste fue sometido. Estas señales analógicas son pasadas a través de un bloque de filtrado (Anti-Aliasing Filter), para remover las frecuencias no deseadas, y posteriormente a un bloque de muestreo a determinada frecuencia con el objetivo de poder ser utilizadas como patrones de entrenamiento para la estructura neuronal. No toma en cuenta las señales de tipo discretas (interruptores y relevadores).

Una ventaja considerable del sistema de diagnóstico propuesto es que su implementación no requiere de la utilización de un configurador de red del sistema, no depende del tamaño de la red eléctrica, ni de volver a entrenar los módulos neuronales si la red eléctrica aumenta en tamaño, pudiéndose aplicar a un solo componente, a una zona específica, o a todo el contexto del sistema de potencia. El método se refuerza para emitir un diagnóstico más preciso al tomar en cuenta tanto las señales analógicas de voltajes y corrientes de falla de las líneas de transporte, como las discretas (estado de interruptores y relevadores).

## 1. DESCRIPCIÓN DEL MÉTODO DE DIAGNÓSTICO

Con la finalidad de poder explicar a conciencia la metodología propuesta, se toma a manera de ejemplo la subestación Mérida (MDA-115 Kv) a interruptor y medio, perteneciente a la zona Mérida del área peninsular del sistema eléctrico mexicano, la cual interconecta a la subestación Metropolitana (MTO-115Kv) a través de la línea L, como se aprecia en la figura 1.1. El método se aplicará por facilidad exclusivamente a la línea de transporte L <sup>7 8 9</sup>.

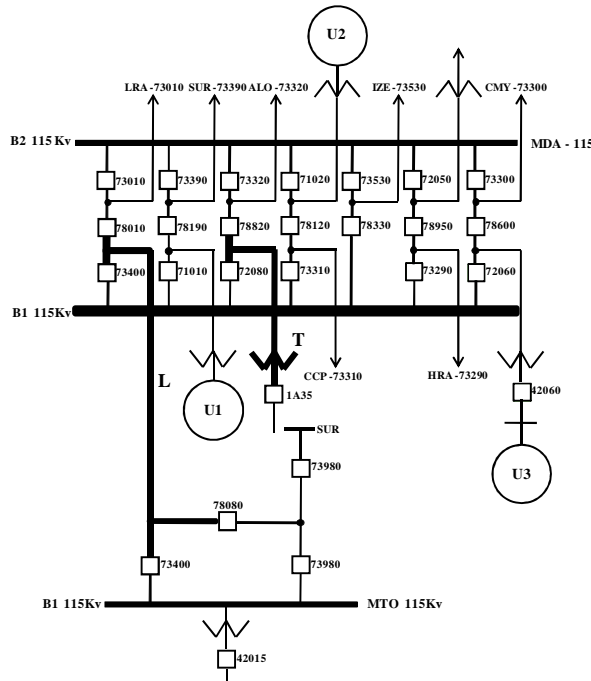


Figura 1.1 Topología de interconexión de L

### 1.1 PRIMER NIVEL DE DIAGNÓSTICO (POR INTERRUPTORES)

La línea de transporte L a la cual se hará referencia es la L MDA -73400- MTO, y se conecta en cada uno de sus extremos a subestaciones a interruptor y medio. Los interruptores primarios por medio de los cuales la línea L se conecta a ambas subestaciones MDA-115 y MTO-115 de acuerdo a la figura 1.1 son: MDA INT-73400, MDA INT-78010, MTO INT-73400, MTO INT-78080.

Todo componente de una red eléctrica está caracterizado por un grupo de esquemas de protección que lo protegen contra fallas de cortocircuito.

Para el caso de la línea de transporte L, perteneciente a la subestación MDA-115, el esquema de protección primaria está representado por un relevador 21 de distancia para fallas entre fases y un relevador 21N de distancia para fallas de fase a tierra. Este tipo de protección es clásico para líneas de tipo radial o largas, por lo que en el caso de líneas malladas o cortas, el esquema de protección primaria puede estar caracterizado por un relevador diferencial 87L.

El esquema de protección secundaria esta implementado por un relevador de sobre-corriente direccional 67 para fallas entre fases y un relevador de sobre-corriente direccional 67N para fallas de fase a tierra.

El esquema de protección de respaldo o adicional para este caso está constituido por un relevador de sobre-corriente instantáneo 50FI, y está directamente relacionado a cada interruptor.

Tomando como base de que para toda activación de un relevador, corresponde la apertura de un interruptor, si ocurre una falla en la línea de transmisión L, el conocimiento que el módulo neuronal tendrá que aprender será implementado en base a los siguientes criterios:

Si la falla es realmente en L, los interruptores primarios de ambos extremos INT's MDA-73400, 78010, INT's MTO-73400, 78080 deberán de abrir.

## **LADO ENVÍO**

Si falla el INT MDA-73400, los interruptores de respaldo que deberán de abrir para evitar que la falla se propague son en este caso MDA-71010, 72080, 73310, 78330, 73290, 72060.

Si falla el INT MDA-78010, los interruptores de respaldo que deberán de abrir para evitar que la falla se propague son en este caso INT MDA-73010, INT LRA-73010.

## **LADO RECEPTOR**

Si falla el INT MTO-73400, los interruptores de respaldo que deberán de abrir para evitar que la falla se propague son en este caso MTO-73980, 42015.

Si falla el INT MTO-78080, los interruptores de respaldo que deberán de abrir para evitar que la falla se propague son en este caso MTO-73980, SUR-73980.

### **1.1.1 IMPLEMENTACIÓN DE LA BASE DE CONOCIMIENTO CON LA CUAL SERÁ ENTRENADO EL MÓDULO NEURONAL**

En la tabla 1 se presentan las principales combinaciones lógicas de los estados de los interruptores en un extremo de la línea de transporte L (lado envío).

Tomando como base los patrones anteriores y las diferentes combinaciones que contemplan falla en los interruptores de respaldo, se generan 250 patrones de entrenamiento con los cuales se entrenará una red neuronal perceptron multicapa back-propagation<sup>17</sup><sup>18</sup>, que tendrá como entrada los mencionados patrones y como salida la activación de que la falla fue en la línea bajo diagnóstico, tomando en cuenta solo la apertura de interruptores en un extremo (Lado envío). Esta estructura neuronal estará formada por una capa de entrada con 11 neuronas y una de salida con una sola neurona. Cabe mencionar que este diagnóstico solo está ubicado en un extremo de la línea (Lado Envío), por lo que es necesario tener ubicada una red neuronal similar con la misma combinación de patrones y la misma salida, en el otro extremo de la línea (Lado receptor), ya que la línea se conecta en ambos extremos a subestaciones con interruptor y medio.

La combinación de los resultados de las redes neuronales de ambos extremos (envío y recepción) dará el diagnóstico final sobre el componente, en este caso la línea L<sup>11 12 13 14</sup>. Para esta combinación se construye una tabla lógica de decisión que tiene como entradas las activaciones en cada uno de los extremos de la línea L, y como salida la verificación por interruptores de que la falla está en la línea. Esta tabla de decisión es implementada por una estructura neuronal formada por una capa de entrada con dos neuronas y una capa de salida con una sola neurona. La estructura modular completa puede ser apreciada en la figura 1.2.

BREAKERS (S.E Breaker and a Half)										
1	2	3	4	5	6	7	8	9	10	11
INT MDA-73400	INT MDA-78010	INT MDA-72060	INT MDA-71010	INT MDA-73290	INT MDA-78330	INT MDA-73310	INT MDA-72080	INT MDA-73010	INT LRA-73010	*
0	0	1	1	1	1	1	1	1	1	1
0	1	1	1	1	1	1	1	0	0	0
1	0	0	0	0	0	0	0	1	1	1
1	1	1	1	1	1	1	1	1	1	1
1	0	1	1	1	1	1	1	1	1	1
0	1	1	1	1	1	1	1	1	1	1

Tabla 1 Estados lógicos de los interruptores primarios en un extremo de L (Lado envío)

## 1.2 SEGUNDO NIVEL DE DIAGNÓSTICO (POR RELEVADORES)

Con el módulo neuronal anterior se determina la existencia de la falla en la línea L, exclusivamente por la apertura de los interruptores tanto primarios como de respaldo que están directamente relacionados con la línea. Puede darse el caso que con el solo estado de los interruptores no pueda determinarse si efectivamente la falla está en la línea por falta de información, por lo que se hace necesario reforzar este diagnóstico mediante la validación de los esquemas de protección directamente relacionados con la línea L. Se tienen tres esquemas de protección por cada interruptor primario asociado a la línea y si la falla es realmente en L, al menos un relevador de ambos extremos de la línea debe activarse.

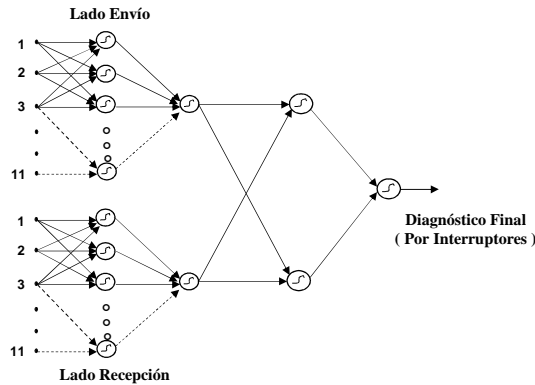


Figura 1.2 Red modular para el diagnóstico de fallas por interruptores en la línea L

Se construye una tabla lógica de decisión para la determinación de la activación de los esquemas de protección de cada uno de los interruptores primarios. Esta tabla lógica será implementada por una estructura neuronal formada por una capa de entrada con cinco neuronas y una capa de salida con una sola neurona. Esta red neuronal será aplicada para cada uno de los interruptores primarios de ambos extremos de la línea L, de forma tal que la combinación de los resultados de estas redes neuronales dará el diagnóstico final sobre el componente, en este caso la línea L. Para esta combinación se construye una tabla lógica de decisión que tiene como entradas las activaciones de cada uno de los esquemas de protección de cada interruptor, y como salida la verificación por relevadores de que la falla está en la línea. Esta tabla lógica será implementada por una estructura neuronal con una capa de entrada con cuatro neuronas y una capa de salida con una sola neurona.

La estructura neuronal completa para el diagnóstico de la falla tomando exclusivamente los estados de activación de los diferentes esquemas de protección de la línea L, puede ser apreciada en la figura 1.3.

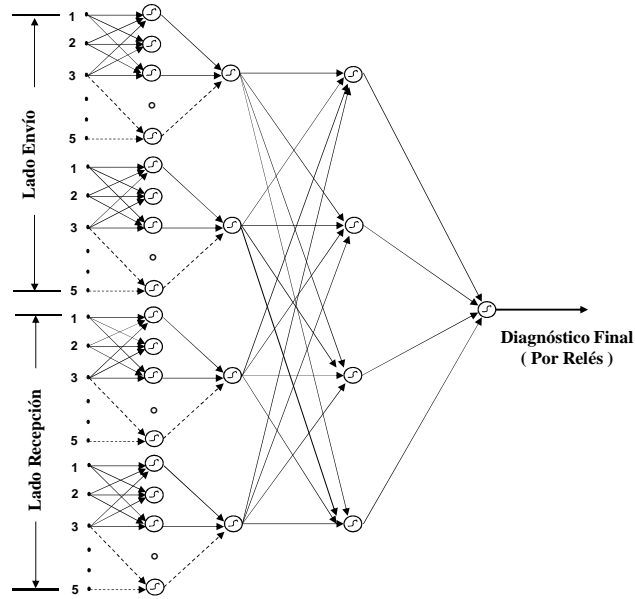


Figura 1.3 Red modular para el diagnóstico de fallas por esquemas de protección

Para llevar a cabo la validación de la falla en la línea tomando en cuenta los diagnósticos, tanto por interruptores como por esquemas de protección, se construye una tabla lógica de decisión que tiene como entradas la verificación de la falla en la línea L por interruptores y por relevadores. Para que la falla en la línea sea validada, los dos niveles previos de diagnóstico, deberán de ser confirmados, por el contrario la falla en la línea será descartada. Esta tabla lógica es implementada por una estructura neuronal con una sola capa de entrada con dos neuronas y una capa de salida con una sola neurona.

La estructura neuronal total para el diagnóstico de la falla en la línea L, por interruptores y esquemas de protección se puede apreciar en la figura 1.4.

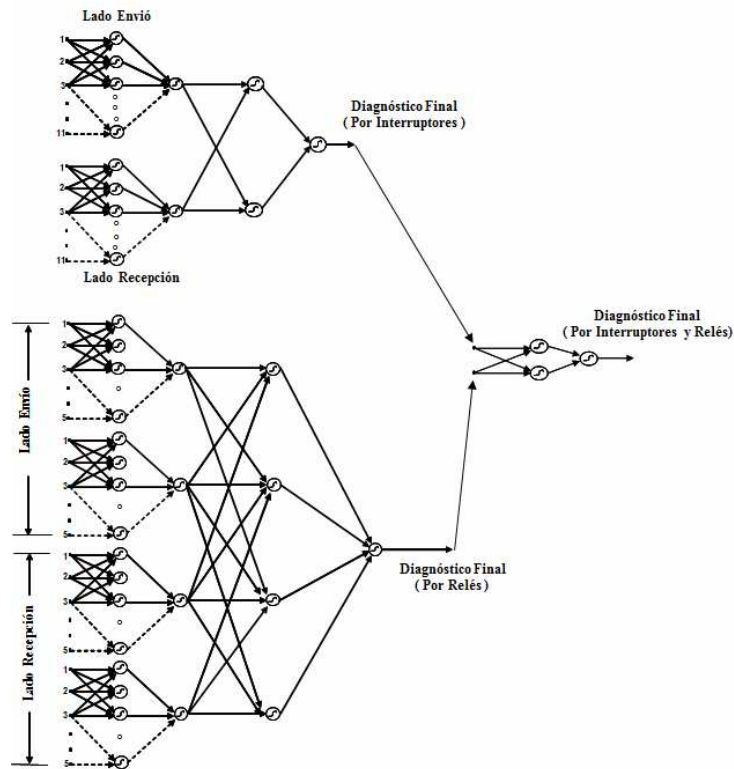


Figura 1.4 Estructura neuronal total para el diagnóstico de fallas en líneas por interruptores y esquemas de protección

Cabe mencionar que tanto para los buses como para los transformadores se sigue el mismo procedimiento de implementación descrito para las líneas de transporte.

### **1.3 TERCER NIVEL DE DIAGNÓSTICO (POR OSCILOGRAMAS DE CORRIENTES Y VOLTAJES DE FALLA)**

Con la finalidad de tener un sistema de diagnóstico de fallas más preciso y confiable, se refuerza el diagnóstico obtenido de la validación final con los dos niveles de diagnóstico previamente establecidos, para las líneas de transporte falladas, mediante un tercer nivel de verificación, que procesa los oscilogramas de voltajes y corrientes de falla de la línea correspondiente, así como los espectros de frecuencia de estos oscilogramas, a través de una estructura neuronal, para verificar si realmente estuvo sujeta a una falla y a la vez determinar el tipo de ésta (L-g, LL-g, LL, LLL, LLL-g). Este proceso se puede llevar a cabo ya que toda línea de transporte que es sometida a una falla presentará corrientes y voltajes de falla, antes de que ésta sea aislada del sistema por sus respectivos esquemas de protección.

#### **1.3.1 MODELO DE LA LÍNEA DE TRANSPORTE PARA LA OBTENCIÓN DE LOS TIPOS DE FALLA**

La base de datos que representará a los patrones de entrenamiento para la estructura neuronal propuesta para el tercer nivel de diagnóstico, estará conformada por la caracterización de cada una de las dinámicas de los diferentes tipos de fallas que se pueden suscitar en una línea de transporte (L-g, LL-g, LL, LLL, LLL-g). Estas dinámicas son obtenidas a partir de simulaciones realizadas en el PowerSys Blockset de MatLab con los parámetros característicos de la línea de transporte antes mencionada y que corresponden a una línea de transporte de 13 Km a un voltaje nominal de operación de 115 Kv.

Cada uno de los tipos de falla será caracterizado por sus oscilogramas de respuesta transitoria correspondientes a cada una de las fases. La base de conocimiento contemplará los oscilogramas de voltaje y corriente como patrones de entrenamiento de cada uno de los tipos de fallas ocurridas en el extremo de envío de la línea, en el centro y en el extremo receptor de esta. Para efectos de explicar el procedimiento se simularán los oscilogramas de voltaje y corriente en el extremo de envío de la línea de transporte (a 3 Km) para una falla de la fase A a tierra, con la finalidad de observar las gráficas correspondientes y poder representarlas en una base de datos para entrenar a la estructura neuronal que se encargará de clasificar el tipo de falla ocurrida en la línea, así como la determinación de que en realidad dicha línea sufrió una falla.

#### **1.3.2 METODOLOGÍA DE CÁLCULO**

Para efectos de simular los oscilogramas de voltaje y corriente de falla para cada uno de los diferentes tipos de falla en el modelo de la línea representado en el PowerSys, se manejará una frecuencia de la señal de 28.8 KHz<sup>19 20 21</sup>. Con esta frecuencia de la señal se garantiza una buena simulación para las señales de corriente y voltaje de tipo analógico que tienen lugar en los registradores de eventos localizados en los extremos de las líneas de transporte.

La reproducción de las señales para efectos de simulación, a una frecuencia de 28.8 KHz y a un tiempo de simulación de 0.1 segundos, corresponde a un tiempo de integración de 34.722 µseg, y a 2880 puntos para cada una de las señales simuladas.

El tiempo de simulación será de 0.1 segundos, ya que este tiempo corresponde a 6 ciclos de la señal de corriente o voltaje, donde los dos primeros ciclos corresponden a la dinámica de la señal previa a la falla, los tres ciclos siguientes corresponden a la dinámica de la falla, y el último ciclo corresponde a la dinámica en donde la falla ya es liberada.

#### **1.3.3 PROCESO DE FILTRADO Y MUESTREO**

Se demuestra que manejando una frecuencia de 28.8 KHz para las señales de corriente y voltaje de falla es posible reproducir mediante simulaciones los diferentes tipos de fallas que se pueden dar en una línea de transporte. Para poder acondicionar las señales analógicas de voltaje y corriente se incluye en el modelo representado en el PowerSys un filtro pasa bajo de segundo orden con el objeto de eliminar las altas frecuencias, y así evitar el problema de aliasing durante el proceso de muestreo<sup>20</sup>. Con la finalidad de poder contar con señales de voltaje y corriente de falla muestreadas y que representen con exactitud a las señales originales de voltaje y corriente de falla, se hace un diezmado a razón de 120, es decir se tomará un punto como muestra cada 120 puntos de cada ciclo dando lugar a 4 puntos (muestras) por cada ciclo de las señales tanto de voltaje como de corriente, de forma

tal que si la dinámica de las señales de voltaje y corriente de falla está caracterizada por 6 ciclos, en total se tendrán 24 muestras que reproducirán de forma exacta a las señales originales<sup>22</sup>. La clasificación de las señales por sectores, puede ser apreciada en la figuras 1.5 y 1.6, donde se representan las dinámicas del voltaje y la corriente, para una falla de la fase A a tierra.




Figura 1.5 Voltajes de falla en las diferentes fases y neutro




Figura 1.6 Corrientes de falla en las diferentes fases y neutro

### 1.3.4 ESTRUCTURA DE LA BASE DE DATOS DE ENTRENAMIENTO

A medida de ilustración se presentará la forma en la cual se ordenan los datos que servirán de patrones de entrenamiento para la estructura neuronal. Los patrones de entrada serán obtenidos de las simulaciones correspondientes al tipo de falla.

La base de datos se implementará como sigue: para una falla de la fase A, a tierra, la información de las corrientes y voltajes de las diferentes fases representada en las figuras 1.5 y 1.6, y en este caso en particular a 3 Kilómetros de distancia, de la barra de envío de la línea de transporte antes mencionada, se agrupará como se muestra en la tabla 2. Las ocho primeras columnas representan los valores del voltaje y la corriente de cada una de las fases, donde en este caso en específico estos valores corresponden a una falla de la fase A, a tierra, y a tres kilómetros de distancia del nodo de envío de la línea de transporte. Las últimas cuatro columnas representan el tipo de falla en forma binaria al cual se hace referencia, en este caso como ya se comentó, una falla de la fase A, a tierra.

En forma descendente se colocan las estructuras de datos para las fallas de la fase A, a tierra, en el centro de la línea (6.5 Km), y en el extremo receptor de esta. En total se tienen 72 patrones de entrenamiento y que caracterizan a una falla de línea a tierra, en este caso de la fase A, en tres diferentes posiciones de la línea: en el extremo de envío (3 Km), a la mitad de la línea (6.5 Km), y por último en el extremo receptor de la línea (3 Km). El manejar tres posibles posiciones de la falla en la línea provee de una buena capacidad de generalización a la estructura neuronal, ya que con estas tres posibles ubicaciones de la falla, la estructura neuronal es capaz de clasificar adecuadamente el tipo de falla a la que es sometida la línea. Esta estructura completa de agrupamiento, se repite para cada uno de los tipos de falla, es decir, se tendrán 11 agrupamientos de a 72 patrones dando un total de 792 patrones de entrenamiento. Las salidas de cada agrupamiento al igual que el primero, representan en forma binaria el tipo de falla al que el agrupamiento hace referencia.



Fa_n	1	2	3	4	5	6	7	8	SALIDA				Muestras
	Vfa	lfa	Vfb	lfb	Vfc	lfc	Vg	Ig	Ffa	Ffb	Ffc	Ft	
1º Ventana	-0.000641867	-3.89083E-05	-0.001196415	-0.000115795	0.001838282	0.000154703	-1.28535E-16	2.94942E-19	0	0	0	0	1
	0.973501524	-0.076403259	-0.341666999	0.038533053	-0.631834526	0.037870206	-6.91105E-14	1.37198E-15	0	0	0	0	2
	0.156566273	0.002870909	-0.922627797	0.062640947	0.766061524	-0.065511856	3.39279E-14	8.94746E-17	0	0	0	0	3
	-0.977512891	0.075485554	0.364054716	-0.043150787	0.613458175	-0.032334767	6.83136E-14	-1.3745E-15	0	0	0	0	4
	-0.130876088	-0.005686783	0.913497316	-0.064549946	-0.782621228	0.070236728	-3.57852E-14	-5.31128E-17	0	0	0	0	5
	0.980884519	-0.076176684	-0.388121653	0.041806383	-0.592762866	0.034370311	-6.73465E-14	1.37569E-15	0	0	0	0	6
	0.105208833	0.006836513	-0.903372829	0.06041348	0.798163996	-0.067249992	3.75514E-14	1.70883E-17	0	0	0	0	7
	-0.983615903	0.075157898	0.4118215	-0.046419404	0.571794403	-0.028738494	6.63519E-14	-1.37607E-15	0	0	0	0	8
2º Ventana	-0.085390516	-0.009294317	0.893416538	-0.062237336	-0.812232671	0.071861669	-3.93077E-14	0.000694649	1	0	0	1	9
	0.794482606	0.244448121	-0.41313357	0.051890314	-0.528477208	0.037597989	-6.87857E-14	0.435579785	1	0	0	1	10
	0.07857321	0.608565667	-0.883929869	0.070899477	0.824708251	-0.055939163	4.14844E-14	0.812910497	1	0	0	1	11
	-0.780159859	0.298755448	0.434207722	-0.044746113	0.504871283	-0.020256067	6.79103E-14	0.304993572	1	0	0	1	12
	-0.043255913	-0.097347222	0.870970136	-0.061615551	-0.839513012	0.071455966	-4.29452E-14	-0.113640457	1	0	0	1	13
	0.795320502	0.185590131	-0.458668486	0.053684383	-0.484590465	0.032579109	-6.65731E-14	0.354537359	1	0	0	1	14
	0.035436192	0.539746239	-0.860491626	0.066775976	0.850674399	-0.058884817	4.49033E-14	0.713893895	1	0	0	1	15
	-0.784244924	0.2154572	0.479820124	-0.049547695	0.460982222	-0.018303638	6.56191E-14	0.192631481	1	0	0	1	16
	-0.003700022	-0.159990825	0.846601051	-0.060247995	-0.864070832	0.071439863	-4.64465E-14	-0.193629071	1	0	0	1	17
	0.794671736	0.146470088	-0.503122432	0.055762758	-0.439532497	0.027911125	-6.42076E-14	0.300094087	1	0	0	1	18
	-0.007413499	0.488236623	-0.834598405	0.062873078	0.874412279	-0.061256088	4.82739E-14	0.638497717	1	0	0	1	19
-0.785563286	0.149009345	0.523946543	-0.053838314	0.415652817	-0.015916624	6.31095E-14	0.103483911	1	0	0	1	20	
3º Vent	0.036283926	-0.206004065	0.819911852	-0.05837136	-0.886263953	0.071582108	-4.979E-14	-0.251041408	0	0	0	0	21
	0.989358754	-0.071865898	-0.570113161	0.053793186	-0.417184944	0.019281513	-5.86319E-14	0.002047061	0	0	0	0	22
	-0.100636605	0.022449661	-0.801635165	0.04975652	0.900541685	-0.072491386	5.0136E-14	1.41371E-06	0	0	0	0	23
	-0.982484998	0.071828401	0.589385182	-0.058290945	0.39193272	-0.013785476	5.68487E-14	-2.15631E-07	0	0	0	0	24

Tabla 2 Estructura de la base de datos de entrenamiento

### 1.3.5 ESTRUCTURA NEURONAL

La estructura neuronal estará formada por una capa de entrada con 8 entradas, una capa oculta con 14 neuronas y la capa de salida con 4 neuronas. Esta estructura fue la que presento una capacidad mayor de generalización utilizando el algoritmo de retropropagación del error (backpropagation), para la clasificación de patrones para los cuales la estructura neuronal no fue entrenada. La estructura neuronal puede ser apreciada en la figura 1.7.




Figura 1.7 Estructura neuronal clasificadora

### 1.3.6 IMPLEMENTACIÓN DE LA ESTRUCTURA NEURONAL PROPUESTA MEDIANTE LA UTILIZACIÓN DE LA FFT

Para poder llevar a cabo el diseño de la estructura neuronal propuesta, tomando en cuenta los espectros en frecuencia para cada uno de los diferentes tipos de falla para el tercer nivel de diagnóstico, se tomarán en cuenta las señales de voltaje y corriente de falla de tipo analógico muestreadas y se obtendrán para cada una de estas sus respectivos espectros en frecuencia, mediante la aplicación de la FFT (Fast Fourier Transform). Dichos espectros en frecuencia serán tomados como patrones de entrada para implementar la base de conocimiento con la cual será entrenada la estructura neuronal.

### 1.3.7 ESTRUCTURA DE LA BASE DE DATOS DE ENTRENAMIENTO

Los patrones de entrada serán obtenidos de los espectros en frecuencia correspondientes al tipo de falla. La base de datos se representará como sigue: para una falla de la fase A, a tierra, la información de los espectros en frecuencia correspondientes a dicha falla se muestra en la figura 1.8.

Dichos espectros representan a las corrientes y voltajes de falla de la fase A, a tierra, y a tres kilómetros de distancia de la barra de envío de la línea de transporte antes mencionada.

Los valores de cada una de las muestras de los espectros en frecuencia de las señales de voltaje y corriente de falla son ordenados como se muestra en la tabla 3.

Las ocho primeras columnas representan los valores de los espectros en frecuencia del voltaje y la corriente de falla de cada una de las fases, donde en este caso en específico estos valores corresponden a una falla de la fase A, a tierra, y a tres kilómetros de distancia del nodo de envío de la línea de transporte. Las últimas cuatro columnas representan el tipo de falla en forma binaria al cual se hace referencia, en este caso como ya se comentó, una falla de la fase A, a tierra.

En forma descendente se colocan los espectros en frecuencia para las fallas de la fase A, a tierra, en el centro de la línea (6.5 Km), y en el extremo receptor de ésta (3 Km). En total se tienen 39 patrones de entrenamiento y que caracterizan a una falla de línea a tierra, en este caso de la fase A, en tres diferentes posiciones de la línea: en el extremo de envío (3 Km), a la mitad de la línea (6.5 Km), y por último en el extremo receptor de la línea (3 Km). El manejar tres posibles posiciones de la falla en la línea provee de una buena capacidad de generalización a la estructura neuronal, ya que con estas tres posibles ubicaciones de la falla, la estructura neuronal es capaz de clasificar adecuadamente el tipo de falla a la que es sometida la línea.

La estructura neuronal estará formada por una capa de entrada con 8 entradas, una capa oculta con 14 neuronas y la capa de salida con 4 neuronas. Esta estructura es la misma que para el caso de las señales analógicas. A diferencia del caso anterior esta estructura neuronal será entrenada con los espectros de frecuencia de las señales analógicas de voltajes y corrientes de falla como entradas.

## 2. EJEMPLO DE PRUEBA

### FALLA QUÍNTUPLE

Fallas simultáneas en los buses MDA-B1 y MDA-B2 y en las líneas:

- MDA -73400- MTO
- MDA -73390- SUR
- MDA -73310- CCP

Con falla en los interruptores:

- MDA -73400 común al bus MDA-B1 y a la LT MDA -73400- MTO
- MDA -73390 común al bus MDA-B2 y a la LT MDA -73390- SUR.

El resultado arrojado por el sistema de diagnóstico de fallas, puede apreciarse en la figura 1.9.

Con la finalidad de probar la eficiencia del método propuesto, se resuelve el ejemplo anterior mediante una estructura neuronal global (de tipo monolítico) formada por tres capas. La primera capa contiene 38 neuronas correspondientes a los interruptores y relevadores de los componentes a diagnosticar.

La capa oculta se compone de 50 neuronas y la de salida de 5 neuronas cada una relacionada con el componente a diagnosticar. La estructura neuronal es entrenada con patrones representando la operación normal de la red, con falla simple de interruptor y con falla simple de relevadores. Bajo estos patrones de entrenamiento la red responde adecuadamente para fallas simples tanto de interruptores como de relevadores. Para fallas dobles (dos interruptores, dos relevadores o un interruptor y un relevador) la estructura neuronal no responde adecuadamente por lo que es necesario entrenarla con patrones de fallas dobles.




Figura 1.8 Espectros en frecuencia de voltajes y corrientes de falla. Fase A a tierra

	1	2	3	4	5	6	7	8	S A L I D A				Frecuencia ( Hz )
	Vfa	Ifa	Vfb	Ifb	Vfc	Ifc	Vg	Ig	Ffa	Ffb	Ffc	Ft	
Fa_n	0.007033695	1	0.066764726	0.072867548	0.063212778	0.044367624	0.038724569	1	1	0	0	1	0
	0.014600735	0.724784987	0.066232702	0.014255558	0.062901652	0.122853738	0.038944653	0.729493616	1	0	0	1	10
	0.01030629	0.150954104	0.06447039	0.061800859	0.06207628	0.06541054	0.037920982	0.145938987	1	0	0	1	20
	0.028960996	0.357889031	0.058611054	0.063450208	0.062398401	0.070824747	0.032421124	0.361480936	1	0	0	1	30
	0.023695152	0.09287145	0.055379645	0.044911666	0.053648855	0.065105431	0.037657114	0.086774456	1	0	0	1	40
	0.113411159	0.611475116	0.047699773	0.055105264	0.042047094	0.011912668	0.039843497	0.598260141	1	0	0	1	50
	1	0.911160382	1	1	1	1	1	0.83817497	1	0	0	1	60
	0.02983915	0.463881033	0.126227272	0.131691587	0.129328749	0.120233824	0.090278434	0.447269167	1	0	0	1	70
	0.026474385	0.033824881	0.104540063	0.088837824	0.100538511	0.117022147	0.064461925	0.024988575	1	0	0	1	80
	0.036228667	0.094090738	0.09926935	0.082181295	0.089867899	0.109274824	0.063091859	0.097482845	1	0	0	1	90
	0.011660863	0.025035166	0.092567438	0.077643407	0.089559941	0.10597307	0.054709013	0.026073242	1	0	0	1	100
	0.023562444	0.02699031	0.089714578	0.074111549	0.089310466	0.10647508	0.051019199	0.03357082	1	0	0	1	110
	0.000518759	0.019526727	0.090091776	0.074028093	0.087860196	0.10556496	0.052961414	0.025955285	1	0	0	1	120

Tabla 3 Estructura de la base de datos de entrenamiento

Para el caso de fallas triples o más, es necesario presentarle a la estructura neuronal patrones con estos tipos de fallas, para que pueda presentar capacidad de generalización ante estas.

Se puede observar de lo anterior que al aumentar el tamaño de la red la estructura neuronal también crecerá, por lo que para sistemas complejos éste tipo de estructura global se hace cada vez más complicada. La ventaja del método propuesto es que solo se tienen tres estructuras neuronales; una para los buses, una para las líneas y una para los transformadores. La estructura neuronal modular para los buses está formada por dos capas, la capa de entrada con 14 neuronas y la de salida con una neurona. La estructura neuronal para las líneas, también está formada por dos capas, la capa de entrada con 11 neuronas y la de salida con una neurona. La estructura neuronal para los transformadores es similar a la de las líneas. Otra ventaja del método propuesto es que si la red aumenta de tamaño no es necesario entrenar de nuevo a las estructuras neuronales. Una ventaja adicional es que para reforzar el diagnóstico de las líneas de transporte se toman en cuenta tanto las señales discretas (estado de interruptores y relevadores), como las analógicas (voltajes y corrientes de falla).

Con la finalidad de comparar también el método propuesto con métodos de razonamiento basados en lógicas <sup>16</sup>, se resuelve el ejemplo anterior, utilizando 15 hipótesis, una por cada componente candidato a falla. Cada hipótesis está conformada por tres reglas básicas con sus respectivas condiciones de operación normal del componente fallado; falla en interruptores, y fallas en relevadores. El resultado del diagnóstico obtenido bajo este método es igual al método propuesto, a diferencia de que el método propuesto solo ocupa tres módulos neuronales, uno por cada tipo de componente contra 15 hipótesis generadas en el método de razonamiento lógico. Para el método de razonamiento lógico si el sistema crece en número de componentes es necesario generar una nueva hipótesis por cada componente, mientras que en el método propuesto se siguen conservando solo tres módulos neuronales. El método propuesto a diferencia del de razonamiento lógico, ocupa las señales analógicas y espectros de frecuencia de las corrientes y voltajes de falla correspondientes a las líneas de transporte, para confirmar el fallo en estas, en caso de no contar con la información suficiente de interruptores y relevadores proveniente del SCADA.

Falla en MERIDA BUS-1		Falla en MERIDA BUS-2	
<b>Interruptores Primarios Operados</b>		<b>Interruptores Primarios Operados</b>	
INT MDA-72060	- 09:12:23 p.m.-	INT MDA-73300	- 09:12:24 p.m.-
INT MDA-71010	- 09:12:23 p.m.-	INT MDA-72050	- 09:12:24 p.m.-
INT MDA-73290	- 09:12:23 p.m.-	INT MDA-73010	- 09:12:24 p.m.-
INT MDA-78330	- 09:12:23 p.m.-	INT MDA-73530	- 09:12:24 p.m.-
INT MDA-73310	- 09:12:23 p.m.-	INT MDA-71020	- 09:12:24 p.m.-
INT MDA-72080	- 09:12:23 p.m.-	INT MDA-73320	- 09:12:24 p.m.-
<b>Interruptor Primario INT MDA-73400 no Operado</b>		<b>Interruptor Primario INT MDA-73390 no Operado</b>	
<b>Interruptores de Respaldo Operados</b>		<b>Interruptores de Respaldo Operados</b>	
INT MDA-78010	- 09:12:24 p.m.-	INT MDA-78190	- 09:12:24 p.m.-
INT MTO-78080	- 09:12:25 p.m.-	INT SUR-73390	- 09:12:24 p.m.-
INT MTO-73400	- 09:12:25 p.m.-		
<b>Protecciones Activadas</b>		<b>Protecciones Activadas</b>	
50FI-INT MDA-73400	- 09:12:24 p.m.-	50FI-INT MDA-73390	- 09:12:24 p.m.-
87B-MDA BUS-1	- 09:12:24 p.m.-	87B-MDA BUS-2	- 09:12:24 p.m.-

Falla en LT MDA -73390- SUR	Falla en LT MDA -73400- MTO	Falla en LT MDA -73310- CCP	
<b>Diagnostico Referente en el lado de Envio</b>	<b>Diagnostico Referente en el lado de Envio</b>	<b>Diagnostico Referente en el lado de Envio</b>	
<b>Interruptores Primarios Operados</b>	<b>Interruptores Primarios Operados</b>	<b>Interruptores Primarios Operados</b>	
INT MDA-78190	INT MDA-78010	INT MDA-73310	
- 09:12:25 p.m.-	- 09:12:27 p.m.-	- 09:12:30 p.m.-	
<b>Interruptor Primario INT MDA-73390 no Operado</b>			
<b>Interruptores de Respaldo Operados</b>			
INT MDA-73390	INT MDA-72060	INT MDA-78120	
- 09:12:25 p.m.-	- 09:12:27 p.m.-	- 09:12:30 p.m.-	
INT MDA-72050	INT MDA-71010	<b>Protecciones que abanderan al Interruptor Primario INT MDA-73310</b>	
- 09:12:25 p.m.-	- 09:12:27 p.m.-	Rel21	- 09:12:30 p.m.-
INT MDA-73010	INT MDA-73290	<b>Protecciones que abanderan al Interruptor Primario INT MDA-78120</b>	
- 09:12:25 p.m.-	- 09:12:27 p.m.-	Rel21	- 09:12:30 p.m.-
INT MDA-73530	INT MDA-78330	<b>Diagnostico Referente en el lado de Recepcion</b>	
- 09:12:25 p.m.-	- 09:12:27 p.m.-	<b>Interruptores Primarios Operados</b>	
INT MDA-71020	INT MDA-73310	INT CCP-73310	- 09:12:30 p.m.-
- 09:12:25 p.m.-	- 09:12:28 p.m.-	<b>Protecciones que abanderan al Interruptor Primario INT CCP-73310</b>	
INT MDA-73320	INT MDA-72080	Rel21	- 09:12:31 p.m.-
- 09:12:25 p.m.-	- 09:12:28 p.m.-		
<b>Protecciones que abanderan al Interruptor Primario INT MDA-73390</b>			
Rel21	- 09:12:28 p.m.-		
Rel50FI	- 09:12:28 p.m.-		
<b>Protecciones que abanderan al Interruptor Primario INT MDA-78190</b>			
Rel21	- 09:12:28 p.m.-		
Rel50FI	- 09:12:28 p.m.-		
<b>Diagnostico Referente en el lado de Recepcion</b>			
<b>Interruptores Primarios Operados</b>			
INT SUR-73390	INT MTO-78080	INT MTO-73400	
- 09:12:26 p.m.-	- 09:12:28 p.m.-	- 09:12:28 p.m.-	
<b>Protecciones que abanderan al Interruptor Primario INT SUR-73390</b>			
Rel21	- 09:12:26 p.m.-		
<b>Protecciones que abanderan al Interruptor Primario INT MTO-78080</b>			
Rel21	- 09:12:29 p.m.-		
<b>Protecciones que abanderan al Interruptor Primario INT MTO-73400</b>			
Rel21	- 09:12:29 p.m.-		

Figura 1.9 Diagnóstico presentado por el sistema de diagnóstico de fallas para una falla quintuple

### 3. CONCLUSIONES

La aplicación de este nuevo método da como resultado el diagnóstico a nivel componente, ya que se disponen de tres módulos genéricos que serán llamados en función del tipo de componente a diagnosticar. Esto da lugar a que el diagnóstico se pueda llevar a cabo por componente, por zona o para todo el contexto del sistema eléctrico. El método se refuerza considerando para el diagnóstico de la línea de transporte correspondiente, tanto los oscilogramas como los espectros de frecuencia de los voltajes y corrientes de falla, mediante una estructura neuronal, para verificar si realmente estuvo sujeta a una falla y a la vez determinar el tipo de esta (L-g, LL-g, LL, LLL, LLL-g). Esto es posible ya que se llamaran a cada uno de los módulos genéricos las veces que un componente se encuentre en el sistema (líneas, transformadores, buses).

También se observa que esta estructura neuronal modular es factible de ser utilizada como herramienta por los operadores de los centros de control.

### 4. REFERENCIAS

- ZhuYongli, Huo Limin, Lu Jinling, "Bayesian Networks-Based Approach for Power System Fault Diagnostic", IEEE Transactions on Power Delivery, Vol. 21 No. 2, 2006.
- Nuno Malheiro, Zita Vale, Carlos Ramon, Albino Marques, Vieira Couto, "On-line Fault Diagnosis with Incomplete Information in a Power Transmission Net-work", Rede Electrica Nacional, S.A Portuguese Electricity Transmission, 2005 ISAP.
- Michael Negnevitsky, Vsevolod Pavlovsky, "Neural Networks Approach to Online Identification of Multiple Failures of Protection Systems", IEEE Transactions on Power Delivery, Vol. 20 No. 2, 2005.
- Jiang Huilan, Guan Ying, Li Dongwei, Xu Jianqiang, "Self - adaptive Clustering Algorithm Based RBF Neural Network and its Application in the Fault Diagnosis of Power Systems", IEEE/PES Transmission and Distribution Conference & Exhibition, Asia and Pacific Dalian China 2005.
- Jing Sun, Shin-Yin Qin, Yong-Hua Song, "Fault Diagnosis of Electric Power System Based on Fuzzy Petri Nets", IEEE Transactions on Power Systems, VOL. 19, No. 4, 2004.

Agustin Flores-Novelo, Eduardo Quiles-Cucarella, Emilio García-Moreno, Francisco Morant-Anglada

6. S. D. J. McArthur, E. M. Davidson, J. A. Hossack, J. R. McDonald, "Automatic Power System Fault Diagnosis through Multi-Agent System Technology", International Conference on System Sciences, 2004.
7. Raj Aggarwal, Yonghua Song, "Artificial Neural Networks in Power Systems, Part1: General Introduction to Neural Computing", Power Engineering Journal, 1997.
8. Raj Aggarwal, Yonghua Song, "Artificial Neural Networks in Power Systems, Part2: Types of Artificial Neural Networks", Power Engineering Journal, 1998.
9. Raj Aggarwal, Yonghua Song, "Artificial Neural Networks in Power Systems, Part3: Examples of Applications in Power Systems", Power Engineering Journal, 1998.
10. A. Sittithumwat, K. Tomsovic, "Dynamic Security Margin Estimation with Preventive Control Using Artificial Neural Networks" IEEE Power Engineering Society Summer Meeting, 2002.
11. T.Yalcinoz, M.J Short, B.J. Cory "Security Dispatch Using the Hopfield Neural Network". IEE Proceedings, Generation, Transmission and Distribution, Vol 146, No. 5, 1999.
12. Yann-Chang Huang, "Abductive Reasoning Network Based Diagnosis System for Fault Section Estimation in Power System", IEEE Transactions on Power Delivery, Vol. 17, No. 2, 2002.
13. Tianshu Bi, Yixin Ni, Felix F. Wu, Qixu Yang, "Novel Distributed Fault Section Estimation System for Large-Scale Power Networks", Power System and Communications infrastructures for the future, Beijing 2002.
14. A. A. El\_Fergany, M. T. Yousef, A. A. El\_Alaily, "Fault Diagnosis of Power System Using Binary Information of Breakers and relays Through DPNs". International Conference on Power System Technology, Vol 2, 2002.
15. Jun-Fen Wu, Nian-Su Hu, Sheng Hu, Yu Zhao, "Application of Som Neural Network in Fault Diagnosis of The Steam Turbine Regenerative System", Proceedings of the First International Conference on Machine Learning and Cybernetics, Beijing 2002.
16. Juhwan Jung, Chen-Ching Liu, Mingguo Hong, Massimo Gallanti, Giorgio Tornielli, "Multiple Hypotheses and Their Credibility in On-Line Fault Diagnosis", IEEE Transactions on Power Delivery, VOL. 16, No. 2, 2001.
17. A. A. El\_Fergany, M. T. Yousef, A. A. El\_Alaily, "Fault Diagnosis in Power System – Substation Level – Through Hybrid Artificial Neural Networks and Expert System", Transmission and Distribution Conference and Exposition 2001, Vol. 1 pp 207-211.
18. Jia-Zhou He, Zhi-Hua Zhou, Zhi-Hong Zhao, Shi-Fu Chen, "A General Design Technique for Fault Diagnosis Systems", Washington DC, Vol 2, 2001.
19. Tahar Bouthiba, "Fault Location in EHV Transmission Lines Using Artificial Neural Networks", International Journal of Applied Mathematics and Computer Science, Vol. 14, No. 1, 2004.
20. Ernesto Vazquez, Oscar L. Chacon, Hector J. Altuve, "Neural Network-Based Fault Detector for Transmission Line Protection", Mexico-USA Collaboration in Intelligent Systems Technologies Proceedings, 1996.
21. S. M. El Safty, H. A. Ashour, H. El Dessouki, M. El Sawaf, "On-line Fault Detection of Transmission Line Using Artificial Neural Network", POWERCON, 2004.
22. M. Sanaye-Pasand, H. Khorashadi-Zadeh, "Transmission Line Fault Detection & Phase Selection using ANN", International Conference on Power System Transients, 2003.

## Datos de los autores:

### Agustin Flores Novelo

Ingeniero Industrial, Maestría en Ingeniería Eléctrica, Instituto Tecnológico de Mérida CFE Área de Control Peninsular  
Departamento de Redes Eléctricas, Mérida Yucatán, México,  
e-mail: [agustin.flores@cfe.gob.mx](mailto:agustin.flores@cfe.gob.mx)

Agustin Flores-Novelo, Eduardo Quiles-Cucarella, Emilio García-Moreno, Francisco Morant-Anglada

**Eduardo Quiles Cucarrella:**

Ingeniero Industrial, Doctor Ingeniero Industrial, Universidad Politécnica de Valencia España, Departamento de Ingeniería de Sistemas y Automática, Valencia, España,  
e-mail: [equiles@isa.upv.es](mailto:equiles@isa.upv.es)

**Emilio García Moreno**

Ingeniero Industrial, Doctor Ingeniero Industrial, Universidad Politécnica de Valencia España, Departamento de Ingeniería de Sistemas y Automática, Valencia, España  
e-mail: [egarciam@isa.upv.es](mailto:egarciam@isa.upv.es)

**Francisco Morant Anglada**

Ingeniero Industrial, Doctor Ingeniero Industrial, Universidad Politécnica de Valencia España, Departamento de Ingeniería de Sistemas y Automática, Valencia, España,  
e-mail: [fmorant@isa.upv.es](mailto:fmorant@isa.upv.es)