

Document downloaded from:

<http://hdl.handle.net/10251/83369>

This paper must be cited as:

Flores, A.; Quiles Cucarella, E.; García Moreno, E.; Morant Anglada, FJ. (2016). Fault Diagnosis of Electric Transmission Lines Using Modular Neural Networks. IEEE Latin America Transactions. 14(8):3663-3668. doi:10.1109/TLA.2016.7786348.



The final publication is available at

Copyright Institute of Electrical and Electronics Engineers (IEEE)

Additional Information

"(c) 2016 IEEE. Personal use of this material is permitted. Permission from IEEE must be obtained for all other users, including reprinting/ republishing this material for advertising or promotional purposes, creating new collective works for resale or redistribution to servers or lists, or reuse of any copyrighted components of this work in other works."

Fault Diagnosis of Electric Transmission Lines using Modular Neural Networks

A. Flores, E. Quiles, E. García and F. Morant

Abstract— This paper proposes a new method for fault diagnosis in electric power systems based on neural networks. With this method the diagnosis is performed by assigning a neural module for each type of component of the electric power system, whether it is a transmission line, bus or transformer. The neural modules for buses and transformers comprise two diagnostic levels which take into consideration the logic states of switches and relays, both internal and back-up. The neural module for transmission lines also has a third diagnostic level which takes into account the oscillograms of fault voltages and currents, as well as the frequency spectrums of these oscillograms, in order to verify if the transmission line had in fact been subjected to a fault. One important advantage of the diagnostic system proposed is that its implementation does not require the use of a network configurator for the system; it does not depend on the size of the power network, nor does it require retraining of the neural modules if the power network increases in size, making its application possible to only one component, a specific area, or the whole context of the power system.

Keywords— Power systems; Transmission networks; Neural networks; Fault diagnosis; Fault voltages and currents; Frequency spectrum.

I. INTRODUCCIÓN

En la actualidad los operadores de centros de control de los Sistemas de Generación y Transporte de Energía Eléctrica se ven abrumados por la gran cantidad de información que en su momento deben 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 sistema SCADA y los elementos 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 elementos fallados y dispositivos de protección operados.

El presente trabajo tiene como objetivo fundamental desarrollar una 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 el sistema eléctrico colapsado.

Las redes neuronales artificiales (ANNs) son algoritmos de procesamiento en paralelo inspiradas en las redes neuronales de los cerebros biológicos. Las ANNs son sistemas adaptables con capacidad de aprendizaje y de generalización ante nuevos datos. Esta capacidad de aproximar relaciones de orden elevado y el procesamiento en paralelo las hacen herramientas adecuadas para el análisis no lineal de sistemas grandes y complejos como son los sistemas eléctricos de potencia.

Se entrenan las redes para que detecten y diagnostiquen los fallos en las líneas de la red de transporte. Se emplea una estrategia de aprendizaje supervisado para el entrenamiento de la red con los patrones de fallo. Se presentan como input a la ANN el estado de las protecciones e interruptores en la red junto a las tensiones y corrientes de falla convenientemente procesadas. Como output se obtiene la ubicación de la línea fallada y el tipo de fallo que ha ocurrido.

En las últimas décadas se han desarrollado trabajos empleando redes neuronales para la predicción de la demanda [1] o el control de tensiones [2] en redes eléctricas. También se han empleado para el diagnóstico de fallas diferentes estructuras neuronales tales como redes Bayesianas [3], redes de funciones de base radial (RBF) [4], [5], perceptrones [4], [6], redes SOM [7], 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 envergadura se empieza a hacer más complicado implementarlas [8], [9], [10].

El método de diagnóstico propuesto se compone de tres niveles de verificación: los dos primeros se conectan en forma seriada, de forma tal que el primer nivel de diagnóstico verifica si la falla fue en el elemento bajo análisis mediante la operación correcta de los interruptores propios y/o de respaldo asociados a este. El segundo nivel de diagnóstico verifica si la falla fue en el elemento bajo análisis mediante la operación correcta de los esquemas de protección propios y/o de respaldo de este. Con el resultado de los dos niveles de diagnóstico previamente establecidos, se hace una validación final, de forma tal que es necesario que los dos niveles de verificación resulten verdaderos para que la falla sea asignada al elemento bajo análisis, de lo contrario la falla no corresponderá a este. La validación final para las líneas de transporte falladas mediante los dos niveles de diagnóstico previos, es reforzada mediante un tercer nivel de verificación, que procesa los oscillogramas de tensiones y corrientes de falla de la línea correspondiente, así como los espectros en frecuencia de estos oscillogramas, a través de una estructura neuronal, para verificar si realmente estuvo sujeta a una falla y

a la vez determinar el tipo de esta (LT, LLT, LL, LLL, LLLT). Este proceso se puede llevar a cabo ya que toda línea de transporte que es sometida a una falla presentará corrientes y tensiones de falla, antes de que esta sea aislada del sistema por sus respectivos esquemas de protección. Es posible probar que se puede obtener un sistema de diagnóstico de fallas más confiable y preciso 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 de los oscilogramas de tensiones y corrientes de falla correspondientes a cada una de las líneas de transporte. Una ventaja considerable del sistema de diagnóstico propuesto es que su implementación puede ser llevada a cabo para un solo elemento, para una zona específica, o para todo el contexto del sistema de potencia.

El presente trabajo se desarrolla en dos secciones: En la primera sección se describe la metodología para el diagnóstico de fallas mediante la implementación de los módulos neuronales relacionados con las señales discretas de los interruptores y relés primarios y de respaldo de cada uno de los elementos que conforman al sistema eléctrico de potencia (líneas de transporte, barras y transformadores). Con la implementación de estos módulos se lleva a cabo la validación de la falla mediante la señalización de la apertura de interruptores y activación de los relés de protección. En la segunda sección se describe la metodología para confirmar la existencia de una falla mediante una estructura neuronal que toma en cuenta los oscilogramas de tensión y corriente de falla así como los espectros en frecuencia de estos oscilogramas.

II. DESCRIPCIÓN DEL MÉTODO DE DIAGNÓSTICO

Con la finalidad de poder explicar 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 MTO a través de la línea L, como se aprecia en la figura 1. El método se aplicará para demostrar su uso exclusivamente a la línea de transporte L [11], [12], [13].

La línea de transporte L, a la cual se hará referencia, es la LT MDA-73400-MTO, y se conecta en cada uno de sus extremos a subestaciones con interruptor y medio. Los componentes primarios (interruptores) por medio de los cuales la línea L se conecta a ambas subestaciones MDA-115 y MTO-115 de acuerdo a la figura 1 son: MDA INT-73400, MDA INT-78010, MTO INT-73400, MTO INT-78080.

Todo elemento 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, mientras que en el caso de líneas malladas o cortas, el esquema de protección primaria puede estar caracterizado por un relevador diferencial 87L.

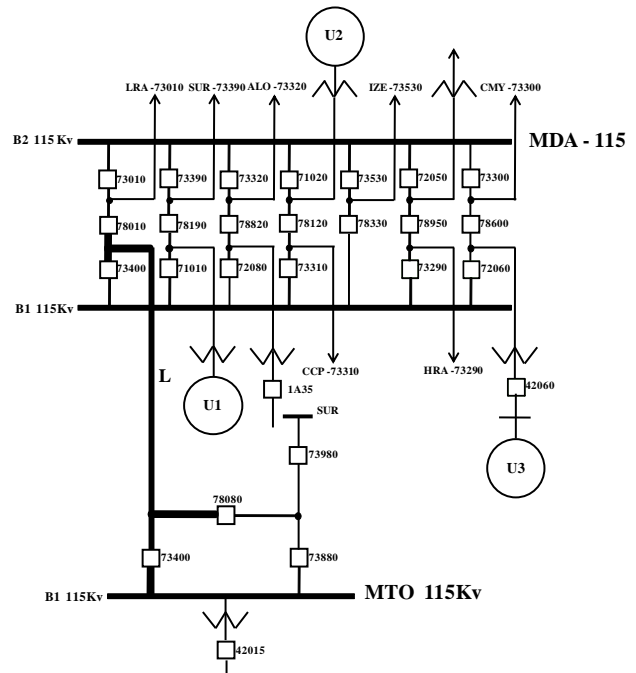


Figura 1 Topología de interconexión de la línea L

El esquema de protección secundaria está 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 secundario 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 que para toda activación de un relevador, corresponde la apertura de un interruptor, si ocurre una falla en L, el conocimiento que el módulo neuronal tendrá que aprender será implementado en dos niveles:

- La detección de la falla en la línea L por la apertura correcta de interruptores.
- La detección de la falla en la línea L por la activación correcta de los esquemas de protección.

- **Por Interruptores**

- 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.
- Si falla el INT MDA-73400, los interruptores de respaldo secundarios 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 secundarios que deberán de abrir para evitar que la falla se propague son en este caso INT MDA-73010, INT LRA-73010.
- Si falla el INT MTO-73400, los interruptores de respaldo secundarios que deberán de abrir para evitar que la falla se propague son en este caso MTO-73980, 42015.

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

• **Por Relevadores**

a) Si la falla es realmente en L, al menos un relevador de ambos extremos de la línea debe activarse (en este caso se tienen 3 esquemas de protección en cada extremo)

Con la finalidad de poder manejar de una manera más adecuada la información del estado de los interruptores y relevadores de protección correspondientes al elemento bajo análisis se presenta en la tabla 1 la base de datos que será aplicada a la lectura de datos relacionados con L provenientes del SCADA.

Inputs	1	2	3	4	5	6	7	8	9	10	11	Local End	
Int_PyR	4	11	1	2	3	5	6	7	18	34	*		
State	1	1	1	1	1	1	1	1	1	1	*		
	INT 4				INT 11								
Relays	21	21N	67	67N	50FI	21	21N	67	67N	50FI		Remote End	
State	0	0	0	0	0	0	0	0	0	0			
Inputs	1	2	3	4	5	6	7	8	9	10	11		
Int_PyR	35	36	37	51	*	*	*	*	37	38	*		
State	1	1	1	1	*	*	*	*	1	1	*		
	INT 35				INT 36								
Relays	21	21N	67	67N	50FI	21	21N	67	67N	50FI			
State	0	0	0	0	0	0	0	0	0	0			
0	Open Breaker				Activated Relay								
1	Closed Breaker				Deactivated Relay								

Tabla 1. Base de datos para la línea de transporte MDA -73400- MTO

La base de conocimiento [14], [15], [16] para el módulo neuronal de diagnóstico será implementada bajo dos niveles:

- a) **Por Interruptores:** donde mediante la apertura correcta de los interruptores primarios y de respaldo secundarios, se ubica la falla en la línea.
- b) **Por esquemas de Protección:** donde mediante la activación correcta de los esquemas de protección, se ubica la falla en la línea.

a) **Por Interruptores**

Tomando como referencia la Base de Datos correspondiente a la línea MDA-73400-MTO se generan los patrones de fallo según la lógica de operación de los interruptores primarios que se ha expuesto anteriormente. Tomando como base los patrones anteriores y las diferentes combinaciones que contemplan falla en los interruptores de respaldo secundario [17], [18], [19], [20], [21] se generan 250 patrones de entrenamiento con los cuales se entrenará una red neuronal tipo perceptron que tendrá como entrada los mencionados patrones y como salida la activación de que la falla fue en la línea bajo diagnóstico. 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 los mismos 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) darán el diagnóstico final sobre el elemento, en este caso la línea L. Esta

combinación se hará en base a las reglas lógicas. La estructura modular completa puede ser apreciada en la figura 2.

b) **Por esquemas de Protección**

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 secundarios que están directamente relacionados con la línea L. 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. En este caso se tienen tres esquemas de protección por cada interruptor primario asociado a la línea y recordando que si la falla es realmente en L, al menos un relevador de ambos extremos de la línea debe activarse.

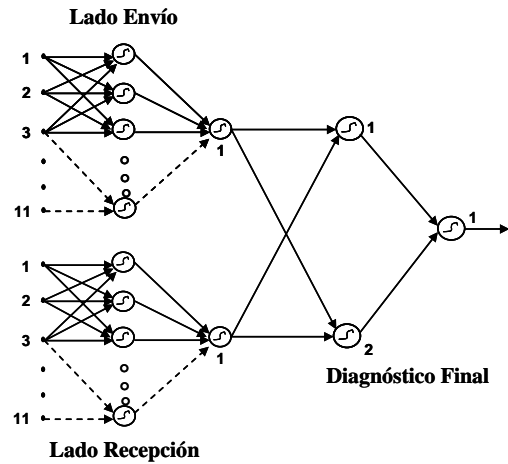


Figura 2. Red modular para el diagnóstico de fallas por interruptores en la línea L

La lógica para la determinación de la activación de los esquemas de protección de cada uno de los interruptores primarios es implementada por una red neuronal tipo perceptron, que tendrá como entradas las activaciones de cada uno de los esquemas de protección pertenecientes a cada interruptor. 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 darán el diagnóstico final sobre el elemento, en este caso la línea L. Para que se de cómo válida la falla en la línea se requiere que tanto la validación por interruptores como por esquemas de protección sean confirmadas, de otra manera se descartará la falla en la línea L.

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

Para evaluar la funcionalidad de la aplicación desarrollada se analiza un fallo histórico de la red. El 4 de marzo del año 2008 ocurre una falla en la línea de transporte NCM -73870-KNP a las 4:01:46 h. El resultado obtenido al aplicar el sistema de diagnóstico tomando en este caso los datos de la base de datos histórica se muestra en la figura 3.

Fallas Detectadas	
Falla en LT KNP -73870- NCM II	
Diagnostico Referente en el lado de Envío	
Interruptores Primarios Operados	
INT KNP-73870	- 04:01:47 a.m.-
Protecciones que abanderan al Interruptor Primario INT KNP-73870	
RelPRIM1	- 04:01:46 a.m.-
Diagnostico Referente en el lado de Recepcion	
Interruptores Primarios Operados	
INT NCM -73870	- 04:01:46 a.m.-
Protecciones que abanderan al Interruptor Primario INT NCM -73870	
RelPRIM1	- 04:01:46 a.m.-

Figura 3. Diagnóstico arrojado por el diagnosticador neuronal ante el evento ocurrido en la LT KNP -73870- NCN II

III. DETECCIÓN DE FALLAS EN LÍNEAS DE TRANSPORTE MEDIANTE OSCIOGRAMAS DE CORRIENTES Y TENSIONES DE FALLA

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

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. 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 LT de 13 km a una tensión 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 tensión 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 tensión y corriente en el centro de la línea de transporte (6.5 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.

Para simular los oscilogramas de tensión 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 [22], [23], [24], [25]. Con esta frecuencia de la señal se garantiza una buena simulación para las señales de corriente y tensión 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 μ s 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 tensión, 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. La clasificación de la señal por sectores puede ser apreciada en la figura 4, que corresponde a la dinámica de la señal de corriente para una falla de la fase A a tierra.

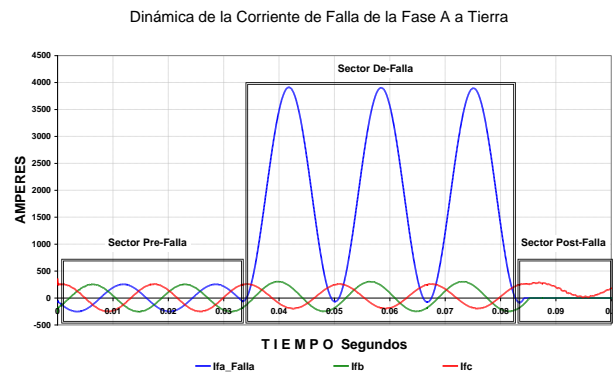


Figura 4. Clasificación de la dinámica de la corriente de falla por sectores

Se demuestra que manejando una frecuencia de 28.8 KHz para las señales de corriente y tensión 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 tensión 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 [23].

Con la finalidad de poder contar con señales de tensión y corriente de falla muestreadas y que representen con exactitud a las señales originales, 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 tensión como de corriente, de forma tal que si la dinámica de las señales de tensión y corriente de falla está caracterizada por 6 ciclos, en total se tendrán 24 muestras que reproducirán de forma exacta a las señales originales [23].

Los patrones de entrada serán obtenidos de las simulaciones correspondientes al tipo de falla. La base de datos se representará como sigue: 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 10 agrupamientos de 72 patrones dando un total de 720 patrones de entrenamiento. Las salidas de cada estructura representan en forma binaria el tipo de falla al que el agrupamiento hace referencia.

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 presentó una capacidad mayor de generalización utilizando el algoritmo de retropropagación del error (back-propagation), para la clasificación de patrones para los cuales la estructura neuronal no fue entrenada.

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 tensión 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.

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 5. Dichos espectros representan a las corrientes y tensiones 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.

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 esta (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). Esta estructura completa de agrupamiento, se repite para cada uno de los tipos de falla, es decir, se tendrán 10 agrupamientos de a 39 patrones dando un total de 390 patrones de entrenamiento. 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 tensiones y corrientes de falla como entradas.

La figura 6 muestra el esquema global del sistema desarrollado de diagnóstico de fallas.

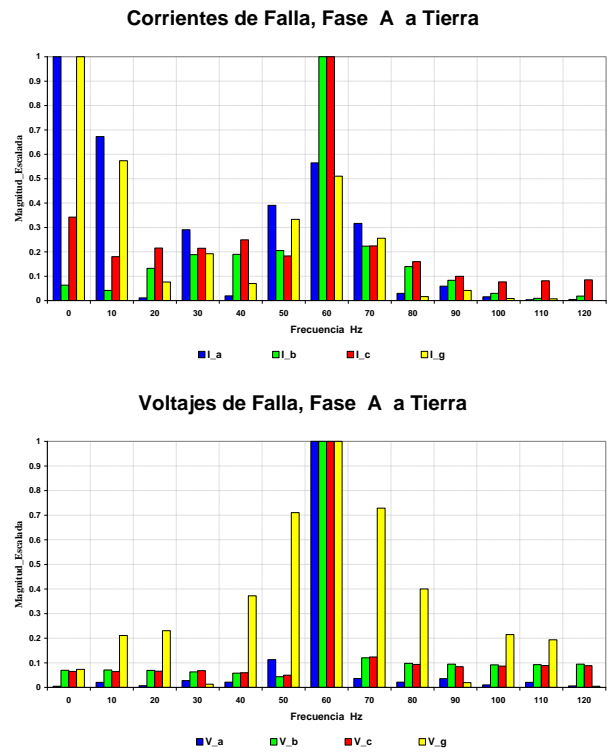


Figura 5. Espectros en frecuencia de corrientes y tensiones de falla. Fase A a tierra

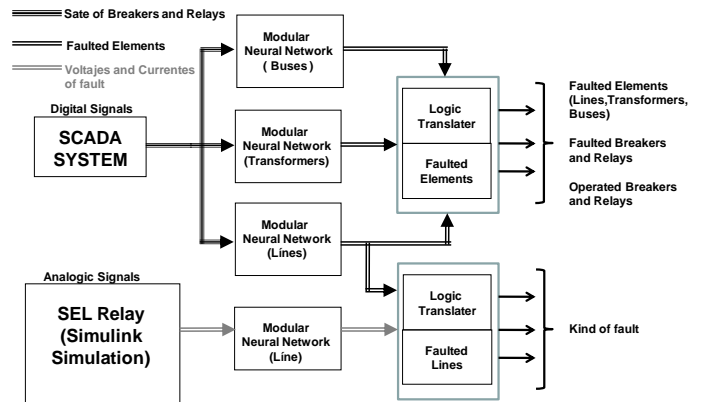


Fig.6. Diagrama de interconexión de los diferentes niveles de diagnóstico.

IV. CONCLUSIONES

La aplicación de este nuevo método da como resultado el diagnóstico a nivel de componentes del sistema, ya que se disponen de tres módulos genéricos que son llamados en función del tipo de elemento a diagnosticar. Dado el carácter modular del método, el diagnóstico se pueda llevar a cabo por elemento, por zona o para todo el contexto del sistema eléctrico.

El método se refuerza considerando para el diagnóstico de la línea de transporte correspondiente los oscilogramas de tensiones y corrientes de falla, así como los espectros en frecuencias de estos oscilogramas, mediante una estructura

neuronal, para verificar si realmente estuvo sujeta a una falla y a la vez determinar el tipo de esta (LT, LLT, LL, LLL, LLLT). Esto es posible ya que se llamaran a cada uno de los módulos genéricos las veces que un elemento se encuentre en el sistema (líneas, transformadores, barras).

También se ha constatado que esta estructura neuronal modular es factible de ser utilizada como herramienta de ayuda a la detección y diagnóstico de averías por los operadores de los centros de control.

REFERENCIAS

[1] Vaschetti, Jorge Carlos; Sauchelli; Victor Hugo. Artificial Neural Network Applied to The Problem of Secondary Voltage Control. IEEE Latin America Transactions. Year: 2012, Volume: 10, Issue: 2. Pages: 1518 - 1524, DOI: 10.1109/TLA.2012.6187595

[2] Trujillo Romero, Felipe; Jimenez Hernandez, Jose del Carmen; Gomez Lopez, Williams. Predicting Electricity Consumption Using Neural Networks. IEEE Latin America Transactions. Year: 2011, Volume: 9, Issue: 7. Pages: 1066 - 1072, DOI: 10.1109/TLA.2011.6129704

[3] Zhu Yongli, Huo Limin, Lu Jinling, Bayesian Networks-Based Approach for Power System Fault Diagnostic, IEEE Transactions on Power Delivery, Vol. 21 No. 2, April 2006.

[4] Nuno Malheiro, Zita Vale, Carlos Ramos, Albino Marques, Vieira Couto, On-line Fault Diagnosis with Incomplete Information in a Power Transmission Network, GECAD - Knowledge Engineering and Decision Support Group Instituto Superior de Engenharia do Porto. REN - Rede Eléctrica Nacional, S.A Portuguese Electricity Transmission.

[5] 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.

[6] A. Sittithumwat and K. Tomsovic "Dynamic Security Margin Estimation with Preventive Control Using Artificial Neural Networks" School of Electrical Engineering and Computer Science, Washington State University. Electricity Supply Industry in Transition: Issues and Prospect for Asia. 14-16 January 2004.

[7] Jun-Fen Wu, Nian-Su Hu, Sheng Hu, and 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, 4-5 noviembre 2002.

[8] 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, April 2005.

[9] Jing Sun, Shin-Yin Qin, Yong-Hua Song, Fault Diagnosis of Electric Power Systems Based on Fuzzy Petri Nets, IEEE Transactions on Power Systems, Vol. 19, No. 4, November 2004.

[10] S.D.J. McArthur, E. M. Davidson, J. A. Hossack, J. R. McDonald, Automatic Power System Fault Diagnosis through Multi-Agent System Technology, Proceedings of the 37th Hawaii International Conference on System Sciences- 2004.

[11] Raj Aggarwal and Yonghua Song. "Artificial Neural Networks in power Systems" Part 1 General Introduction to Neural Computing. Power Engineering Journal. June 1997.

[12] Raj Aggarwal and Yonghua Song. "Artificial Neural Networks in power Systems" Part 2 Types of Artificial Neural Networks. Power Engineering Journal. February 1998.

[13] Raj Aggarwal and Yonghua Song. "Artificial Neural Networks in power Systems" Part 3 examples of Applications in power Systems. Power Engineering Journal. December 1998.

[14] Juhwan Jung, Chen-Ching Liu, Mingguo Hong, Massimo Gallanti, and Giorgio Tornielli, Multiple Hypotheses and Their Credibility in On-Line Fault Diagnosis, IEEE Transactions on Power Delivery, Vol. 16, No. 2, April 2001.

[15] El_Fergany, M. T. Yousef, y A. A. El_Alaily, Fault Diagnosis in Power System -Substation Level- Through Hybrid Artificial Neural networks and Expert System. O-7803-7285-9/01, 2001, IEEE.

[16] Jia-Zhou He, Zhi-Hua Zhou, Zhi-Hong Zhao, y Shi-Fu Chen, A General Desing Technique for Fault Diagnosis Systems, Washington, DC, 2001, vol. 2, pp. 1307-1311.

[17] Albrecht Schmidt and Zuhair Bandar. "A Modular Neural Network Architecture with Additional Generalization Abilities for Large Input Vectors". The Intelligent Systems Group Department of Computing, The Manchester Metropolitan University.

[18] T.Yalcinoz, M.J Short and B.J. Cory. "Security Dispatch Using The Hopfield Neural Network". IEE Proc. Gener. Transm. Distrib., Vol 146, No. 5, September 1999.

[19] Yann-Chang Huang. Abductive Reasoning Network Based Diagnosis Systemfor Fault Section Estimation in Power System, IEEE Transactions on Power Delivery, Vol. 17, No. 2, Abril 2002.

[20] Tianshu Bi, Yixin Ni, Felix F. Wu and Qixu Yang, Novel Distributed Fault Section Estimation System for Large- Scale Power Networks, Power System and Communications infrastructures for the future, Beijing, Septiembre 2002.

[21] A.A El_Fergany, M. T. Yousef, and A.A. El_Alaily, Fault Diagnosis of Power System Using Binary Information of Breakers and relays Through DPNs. 0-7803-7459-2/02, 2002, IEEE.

[22] Tahar Bouthiba, Fault Location in EHV Transmission Lines Using Artificial Neural Networks, Int. J. Appl. Math. Comput. Sci., Vol. 14, No. 1, 2004.

[23] Ernesto Vazquez, Oscar L. Chacon, Hector J. Altuve, Neural Network-Based Fault Detector for Transmission Line Protection, ITESM, 1996.

[24] S. M. El Safty, H. A. Ashour, H. El Dessouki, and M. El Sawaf, On-line Fault Detection of Transmission Line Using Artificial Neural Network, POWERCON, 21-24 November 2004.

[25] M. Sanaye-Pasand and H. Khorashadi-Zadeh, Transmission Line Fault Detection & Phase Selection Using ANN, International Conference on Power System Transients, IPST, 2003 in New Orleans, USA.



reliability.

Agustín Flores Novelo received an M.Sc in Electrical Engineering from the Centro de Investigacion y de Estudios Avanzados del IPN in Mérida (México) in 1982, and a Ph.D. from the Polytechnic University of Valencia (Spain) in 2013. Since 1989 he worked as a system analyst in the electrical network control company in Mérida. His current research areas are fault detection and diagnosis and systems



Eduardo Quiles Cucarella received an M.Sc in Electrical Engineering from the Polytechnic University of Valencia in 1993, and a Ph.D. from the same university in 1998. In 1996 he joined the Systems and Control Engineering Department of the Technical University of Valencia, where he is an associate professor. His current research areas are fault detection and diagnosis and systems reliability.



systems.

Emilio García Moreno received a degree in electronics in the Faculty of Physics of University of Valencia in 1995. He obtained his Ph.D. degree from the Technical University of Valencia in 2000. Since 1989 he has been with the Department of Systems Engineering and Control of the Technical University of Valencia as an associate professor. His research interests are in discrete-event and hybrid



Francisco Morant received an M.Sc in Electrical Engineering from the Polytechnic University of Valencia in 1982, and a Ph.D. from the same university in 1985. In 1985 he joined the Systems and Control Engineering Department of the Technical University of Valencia, where he is an associate lecturer. His current research areas are expert systems control and fault detection and diagnosis.

RESPUESTA A LOS COMENTARIOS DE LOS REVISORES

- 1. Dado que esta revista es bastante generalista, creo conveniente explicar brevemente en algunos apartados la terminología empleada en relación a las redes neuronales, a fin de que el trabajo pueda ser comprendido por gente no experta en esa materia.**

Se ha añadido en la introducción los siguientes párrafos aclaratorios:

“Las redes neuronales artificiales (ANNs) son algoritmos de procesamiento en paralelo inspiradas en las redes neuronales de los cerebros biológicos. Las ANNs son sistemas adaptables con capacidad de aprendizaje y de generalización ante nuevos datos. Esta capacidad de aproximar relaciones de orden elevado y el procesamiento en paralelo las hacen herramientas adecuadas para el análisis no lineal de sistemas grandes y complejos como son los sistemas eléctricos de potencia”.

“Se entrenan las redes para que detecten y diagnostiquen los fallos en las líneas de la red de transporte. Se emplea una estrategia de aprendizaje supervisado para el entrenamiento de la red con los patrones de fallo. Se presentan como input a la ANN el estado de las protecciones e interruptores en la red junto a las tensiones y corrientes de falla convenientemente procesadas. Como output se obtiene la ubicación de la línea fallada y el tipo de fallo que ha ocurrido”.

Para mantener el artículo en una extensión apropiada pero a la vez suministrar toda la información necesaria para su comprensión se han incluido las referencias [11], [12] y [13], que son tutoriales del uso de redes neuronales en sistemas eléctricos de potencia.

También se incluyen las referencias [24] y [25] entre otras, que son introductorias al uso de redes neuronales para el diagnóstico de fallos en redes de transporte de energía eléctrica.

- 2. Aun así, no entiendo gran parte de la metodología descrita en el apartado III, como por ejemplo en qué sentido se usan los espectros de frecuencia para determinar el punto de la falta, o el diagrama mostrado en la figura 6.**

La metodología presentada en el apartado III se basa en aprovechar los registradores de tensiones y corrientes de falla existentes en las líneas de transporte para dotar de un nivel más de diagnóstico a la herramienta desarrollada. Se discretiza la señal de tensión y corriente y se introduce como entrada a la red neuronal los valores adquiridos al inicio, a mitad y al final de la línea. Cabe destacar que la red neuronal encargada de esta parte de diagnóstico se entrena con los patrones de tensiones y corrientes de los 5 tipos de falla. Este entrenamiento se efectuará para las distintas líneas de la red pero sólo en una ocasión.

Además se dispone una segunda red que trabaja con los espectros de frecuencia de las señales de tensión y corriente. El espectro de frecuencia complementa la información obtenida directamente de la señal en el tiempo y dota de mayor robustez a la herramienta de diagnóstico.

La figura 6 muestra el diagrama de bloques de la herramienta de diagnóstico. En la parte superior se muestran las redes neuronales para la detección de faltas en líneas, barras y transformadores. El estado de los interruptores y los relevadores se adquiere directamente del sistema SCADA que monitoriza la red. En la parte inferior del diagrama se incorpora el bloque de diagnóstico correspondiente a las líneas y basado en las tensiones y corrientes de falla.

- 3. En cualquier caso, lo que más me llama la atención es la cantidad de casos que deben prepararse offline para generar los patrones de entrenamiento para el ejemplo de una sola línea. Da la impresión que extrapolar esta técnica a toda las líneas que llegan a una subestación requerirá una cantidad de trabajo ingente, lo que la haría muy poco práctica de realizar en sistemas reales. Si no es el caso, creo que convendría aclararlo de alguna forma.**

La ventaja del método propuesto de diagnóstico frente a otros métodos basados en redes neuronales propuestos en la literatura radica en el carácter modular del mismo. A diferencia de estos otros métodos citados en la introducción del artículo, no se entrena a una única red neuronal para todo el sistema de transporte de energía eléctrica en consideración. Por el contrario se definen tres redes neuronales tipo para cada uno de los principales elementos del sistema. Líneas, buses y transformadores. La metodología de diagnóstico se basa en el estado de relevadores e interruptores (activados o no, abiertos o cerrados) que permiten dilucidar la existencia de una falla para cada tipo de elemento de una manera lógica.

En el artículo se desarrolla el caso de una línea conectada en cada uno de sus extremos a una subestación con tipología de interconexión de interruptor y medio. En una red real sólo sería necesario entrenar redes para líneas, barras y transformadores y para cada una de las variantes de conexión. Además cabe destacar que el entrenamiento se realiza offline en un solo momento y sigue siendo válido ante cambios en la topología de la red a diferencia de otros métodos propuestos en la literatura.