

# Clasificación y Localización de Faltas, utilizando Wavelets y Redes Neurales

Miguel Martínez L<sup>1</sup>, Julio Martínez M<sup>2</sup>

<sup>1</sup> Departamento de Conversión y Transporte de Energía  
Universidad Simón Bolívar  
Caracas - Venezuela  
Tel.:+34 6357876925, e-mail: mmlozano@usb.ve

<sup>2</sup> Dpto. Ingeniería Eléctrica. ETSI Industriales  
Universidad Politécnica de Madrid – España

**Resúmen.** En este trabajo se presenta un algoritmo que permite detectar, clasificar, discriminar y localizar las faltas que se pueden presentar en una línea de transporte de energía, basándose en la información de alta frecuencia (ondas viajeras). Para ello, se utilizan como herramientas de análisis la transformada Wavelet y dos tipos o arquitecturas de redes neurales. Para la validación de la metodología propuesta, se utilizó un sistema de potencia reducido a cuatro barras en 400 kV, el cual fue modelado en el programa de transitorios electromagnéticos ATP/EMTP, para obtener las señales en el dominio del tiempo. Los resultados obtenidos muestran la validez de la metodología planteada, para los escenarios considerados.

**Palabras Clave:** Transformada Wavelet, Protección de sistemas de transporte de energía en alta tensión, Localización de Faltas, Redes Neuronales, Ondas Viajeras.

## 1. Introducción

Una de las grandes áreas de investigación que en los últimos tiempos está teniendo un gran auge en cuanto a desarrollo de métodos novedosos y a cantidad de publicaciones en revistas técnicas de impacto internacional, es la relacionada con la localización de las faltas tanto en sistemas de transporte en alta tensión como en sistemas de sub-transmisión y distribución.

En el caso de este trabajo en particular, se va a centrar el análisis en los sistemas de transporte en alta tensión y se debe fundamentalmente a la imperante necesidad de reducir al mínimo el tiempo de indisponibilidad de una línea por culpa de una falta.

El crecimiento notorio de la demanda junto con las nuevas estrategias de mercado para el suministro eléctrico en todas sus etapas (generación, transporte, distribución y comercialización), han llevado al sistema de transporte a crecer tanto en tamaño, como en complejidad y adicionalmente se le exige trabajar cada vez más cerca de los límites críticos de estabilidad.

Todos estos puntos generan dos temas importantes de abarcar:

- a.- Las nuevas exigencias sobre los sistemas de protección en todo su amplio espectro: selectividad, sensibilidad, confiabilidad, rapidez, adaptabilidad, etc.
- b.- Mayor precisión en la localización de las faltas permanentes a fin de reducir los tiempos de reparación y nueva puesta en servicio.

Para poder atacar convenientemente todas estas nuevas condiciones es indispensable el uso adecuado de técnicas modernas de análisis, sin desvincularse de los avances en el campo del “hardware” para su efectiva y útil implementación.

Hay dos técnicas que caben mencionar por su aplicación en este campo específico de trabajo y que son precisamente las que se van a implementar en el presente artículo:

- 1-) Técnicas de Análisis de Señales (Transformada Wavelet).
- 2-) Técnicas de Inteligencia Artificial (Redes Neuronales).

En general, la información que se obtiene de las señales de tensión e intensidad en el dominio del tiempo, no es suficiente y en general se recurre a su representación en el dominio de la frecuencia [1-3].

Tradicionalmente se ha utilizado para este fin, la transformada de Fourier (TF); sin embargo, el análisis particular de señales no periódicas asociadas con fenómenos electromagnéticos como es el caso de una falta en un sistema de potencia, representa un problema para la TF convencional. La transformada localizada de Fourier (o transformada de Gabor), resuelve parcialmente el problema, aunque se encuentra limitada por depender de un ancho fijo de ventana, lo cual limita la información combinada tiempo-frecuencia.

Sin embargo, la Transformada Wavelet (TW), utiliza anchos de ventana variables (cortos para altas frecuencias

y largos para bajas frecuencias) y permite en general obtener una información adecuada que combine el evento temporal con el espectro de frecuencia. Por ello, ha sido seleccionada como herramienta de análisis en el presente trabajo.

Por otro lado, está el manejo de esa información extraída del análisis y filtrado directo de las señales de tensión e intensidad, a fin de obtener un resultado preciso en cuanto a la tarea concreta que se quiera acometer.

En el campo específico de un algoritmo de protección de líneas de transporte de energía, hay una clasificación de dichas tareas en función del esquema progresivo que debe cumplir, desde la detección del evento, hasta que se efectúa la decisión de dar o no orden de disparo al interruptor asociado y se pueden dividir de forma sucinta, de la siguiente manera:

- 1) Detección del evento.
- 2) Clasificación del tipo de falta e identificación de las fases involucradas.
- 3) Determinación de la dirección de la falta.
- 4) Localización de la falta.

En particular, se consideran críticas la 2 y la 4 y para ellas, se van a utilizar como soporte, las redes neuronales.

Así, en el caso de clasificación, al tratarse de un problema con resultados discretos, se utiliza una red probabilística (PNN) y para el caso de localización de faltas, una que tenga capacidad de generalizar para diferentes escenarios, por lo que se seleccionó una red de base radial (RBFNN).

El uso combinado de Wavelets con redes neuronales, no es nuevo [4] y los resultados obtenidos demuestran su buena funcionalidad incluso en aquellos escenarios donde se involucran compensadores en serie o electrónica de potencia (FACTS).

En definitiva, el objetivo de este trabajo es presentar un algoritmo que realice todas las tareas antes mencionadas, utilizando primordialmente la información de alta frecuencia de las señales (onda viajera), la cual es extraída mediante la TW y posteriormente procesada mediante Redes Neuronales (ANN).

## 2. Transformada Wavelet

Para los efectos de este trabajo el análisis Wavelet puede interpretarse como una técnica que transforma una señal en el dominio del tiempo (corriente y/o tensión) a un dominio denominado tiempo-escala, con el fin de localizar en el tiempo las diferentes componentes del espectro de frecuencia de la señal, hecho particularmente útil para identificar componentes transitorias de la señal que se puedan utilizar como base para desarrollar algoritmos de protección de alta velocidad, como el de onda viajera.

Lo anterior se consigue gracias a la expansión de la señal mediante una descomposición lineal que utiliza como base un conjunto de funciones denominadas Wavelets, que surgen a partir de una función “Wavelet madre”, (1), que actúa como un prototipo para generar funciones bases (“ventanas”) cuyo ancho varía a medida que se evalúa la transformada.

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) \quad (1)$$

Donde “ $\tau$ ” (traslación) es un parámetro que está relacionado con la localización de la ventana a medida que ésta se desplaza a través de la señal, por lo cual este término corresponderá a la información del tiempo en el dominio transformado. Por otro lado “ $s$ ” (escala) es un parámetro que está relacionado con la información en frecuencia de la señal, correspondiendo para cada escala una determinada banda de frecuencias y por ende define el ancho de la ventana.

En la práctica, la Wavelet madre no puede ser una función continua, sino que deben elegirse valores discretos ( $j, k$ ) para los parámetros ( $s, \tau$ ); esto conduce al empleo de la Transformada Wavelet Discreta Diádica (DWT) que resulta muy eficiente al implementarse mediante el análisis multiresolución (MRA).

Para este fin, el MRA se basa en la selección apropiada de una función de escalamiento  $\varphi$  que da origen a dos ecuaciones fundamentales [5], la función de escala  $\varphi(t)$  y la función Wavelet  $\psi(t)$  definidas por (2) y (3), respectivamente.

$$\varphi(t) = \sum_k h(k) \sqrt{2} \varphi(2t - k) \quad k \in \mathbb{Z} \quad (2)$$

$$\psi(t) = \sum_k h_1(k) \sqrt{2} \varphi(2t - k) \quad k \in \mathbb{Z} \quad (3)$$

Estas dos ecuaciones se caracterizan por ser recursivas y por los filtros discretos  $h(k)$  y  $h_1(k)$  que representan los coeficientes de la función de escala y los coeficientes de la función Wavelet, respectivamente.  $h_1(k)$  puede obtenerse a partir de  $h(k)$  como se indica en (4).

$$h_1(k) = (-1)^k h(1 - k) \quad k \in \mathbb{Z} \quad (4)$$

Las funciones de escala y Wavelet son un prototipo de una clase de funciones bases ortogonales que generan un espacio  $L^2(\mathbb{R})$  y que tienen la forma indicada en (5) y (6).

$$\varphi_{j,k}(t) = 2^{j/2} \varphi(2^j t - k) \quad j, k \in \mathbb{Z} \quad (5)$$

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad j, k \in \mathbb{Z} \quad (6)$$

Donde los parámetros “ $j$ ” y “ $k$ ” son la resolución y traslación, respectivamente.

Por lo tanto, con un conjunto de funciones  $\varphi_{j,k}(t)$  y  $\psi_{j,k}(t)$  una función  $f(t)$  puede representarse como una expansión en serie en términos de éstas funciones, (7).

$$f(t) = \sum_k a_j(k) \varphi_{j,k}(t) + \sum_k \sum_{j=0}^{J-1} d_j(k) \psi_{j,k}(t) \quad (7)$$

En la primera sumatoria de (7) los coeficientes  $a_j(k)$  representan una aproximación de  $f(t)$ , con una resolución de un punto por cada  $2^j$  puntos de la señal original. En la segunda sumatoria los coeficientes  $d_j(k)$  representan el detalle de la señal con diferentes niveles de resolución, la cual aumenta a medida que se incrementa el índice “j”. Los coeficientes  $a_j(k)$  y  $d_j(k)$  constituyen por lo tanto una forma de expresar la DWT de la señal, y como las funciones bases elegidas son ortogonales estos coeficientes pueden calcularse mediante el producto interior tal como se muestra en (8) y (9).

$$a_j(k) = \langle f(t), \varphi_{j,k}(t) \rangle = \sum_m h(m-2k)a_{j+1}(m) \quad (8)$$

$$d_j(k) = \langle f(t), \psi_{j,k}(t) \rangle = \sum_m h_1(m-2k)a_{j+1}(m) \quad (9)$$

La estructura de estas ecuaciones constituye una gran ventaja desde el punto de vista de implementación de un algoritmo de cálculo de la DWT, puesto que aplicando la teoría de filtros digitales, los coeficientes  $a_j(k)$  y  $d_j(k)$  definidos por (8) y (9) pueden evaluarse en dos etapas; en primer lugar, se realiza la convolución de los coeficientes de aproximación de la escala “j+1” con los coeficientes de los filtros digitales FIR  $h(-n)$  y  $h_1(-n)$ , donde el filtro FIR implementado como  $h(-n)$  es un filtro paso bajo y se denomina filtro de descomposición (LD) y el filtro implementado como  $h_1(-n)$  es un filtro paso alto y se denomina filtro de descomposición (HD). En segundo lugar, se realiza una reducción de la cantidad de muestras de la señal resultante seleccionando uno de cada dos puntos ( $\downarrow 2$ ). El proceso descrito puede repetirse consecutivamente con los nuevos coeficientes  $a_j$  calculados, constituyéndose una estructura piramidal o algoritmo piramidal de Mallat [5] como se muestra en la Fig. 1.




Fig. 1. Representación del proceso de de descomposición (MRA), mediante la aplicación de bancos de filtros.

### 3. Redes Neuronales

Una de las técnicas que en la actualidad se utiliza para estimar distintas variables en sistemas complejos, a partir de una cantidad limitada de parámetros de entrada, son las redes neuronales [6]. Esto lleva a tomar como punto de partida el uso de las RNA como un método de solución al problema planteado. Sin embargo, uno de los principales problemas al usar las redes neuronales es la selección correcta de la arquitectura y de las variables de entrada. No obstante este asunto es de igual importancia en cualquier método utilizado para estimar, por lo tanto no es una gran desventaja al comparar las RNA con alguna otra herramienta similar utilizada en la actualidad. En los siguientes apartes se entrará en detalle en cuanto a los aspectos tomados en cuenta para la selección de las variables de entrada, según su importancia y relevancia

para la tarea necesaria (clasificación o localización de la falta detectada).

En la actualidad existen tipos de arquitecturas de las ANN (probabilísticas, auto-organizativas, competitivas, de base radial, etc), que además utilizan a la TW como elemento de acondicionamiento para las señales de entrada [4]. En el caso particular de esta publicación, los tipos de ANN a utilizar, son las de base radial y las probabilísticas.

#### A. Redes Neuronales de Base Radial:

Diversos trabajos [7], han demostrado una marcada tendencia al uso de las redes de base radial, en vez de retro-propagación y es que han demostrado que este tipo de redes (RBFNN) tienen excelentes propiedades para resolver problemas con modelos no lineales desde un punto de vista de aproximación a funciones multidimensionales.

Así que dada la condición de poseer data histórica representada por un par de vectores (entrada y salida) para el entrenamiento y asumiendo para el siguiente paso que la salida es unidimensional (que simplifica pero no resta significativa generalidad al planteamiento), se puede definir:

- Entradas:  $X_i \in \mathbb{R}^p$  con  $i = 1, 2, \dots, n$
- Salidas:  $d_i \in \mathbb{R}$

La red con esta función, implementa un mapeo del tipo:  $F(X): \mathbb{R}^p \rightarrow \mathbb{R}$

Donde:

$$F(X) = \sum_{i=1}^M \omega_i G_i(\|X - c_i\|) \quad (10)$$

Donde  $c_i \in \mathbb{R}^p$ , son los centros de las M funciones bases  $G_i$  (funciones exponenciales gaussianas de ancho  $\sigma_i$ )

$$G_i(\|X - c_i\|) = \exp\left(-\frac{\|X - c_i\|^2}{\sigma_i}\right) \quad (11)$$

El vector que contiene los pesos óptimos  $[\omega_i]_{i=1}^M$  es calculado minimizando la siguiente función de costos:

$$\omega = (G^T G + \lambda G_0)^{-1} G^T d \quad (12)$$

Un esquema de este tipo de redes se muestra en la Fig. 2, con “p” entradas y “n” salidas. Cada uno de los “p” componentes del vector  $x$  de entrada, llegan a las M funciones bases  $G_i$ , cuyas entradas se combinan de forma lineal con los pesos  $w_i$ , en cada salida  $F_j(x)$ .




Fig. 2. Esquema de una red neuronal con arquitectura de base radial. “p” entradas, “n” salidas y M funciones  $G_i$ .

## B. Redes Neuronales Probabilísticas

La red neuronal probabilística es ideal para problemas de clasificación [6] y cae dentro del grupo de técnicas de estimación no paramétricas. Esta red está compuesta por tres capas: La primera corresponde a las entradas, una intermedia que puede ser de base radial es una capa de categorización y la última que arroja la salida se basa en un esquema competitivo.

El trabajo se realiza de la siguiente manera: La primera capa calcula las distancias desde el vector de entrada a los vectores de entrenamiento y produce un vector cuyos elementos indican la cercanía entre estos dos vectores (entrada/entrenamiento). La segunda capa, suma las contribuciones para cada clase de entradas y así, producir un vector de probabilidades. Finalmente, una función de transferencia del tipo competitivo, toma el máximo del vector de probabilidades y produce una salida binaria para la clasificación de clases (un "1" para el de mayor probabilidad y un "0" para el resto de posiciones del vector).

La "función" de activación para este caso, consiste en la densidad de probabilidades (DP) entre la entrada y los patrones de entrenamiento. Como se ve, no hay un entrenamiento previo para cálculo de pesos, sino que la capa de categorización calcula el DP para cada vector de entrada, comparándolo con los vectores de entrenamiento para las clases o categorías de salida pre-especificadas.

$$p_n(X) = \frac{1}{n} \sum_{i=1}^n \frac{1}{V_n} \varphi\left(\frac{x-x_i}{h_n}\right) \quad (13)$$

Donde:

"n": es el tamaño del vector de entrenamiento.

$$V_n = \frac{1}{\sqrt{n}} \quad (14)$$

hn: es el factor de agrupamiento.

Y la función  $\varphi$ , viene representada, por:

$$\varphi(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2} \quad (15)$$

Para mayor detalle, hay una página web habilitada con información técnica detallada sobre estas herramientas y su aplicación particular al estudio de las protecciones eléctricas y de localización de faltas (<http://prof.usb.ve/mmlozano/adicional.html>).

## 4. Planteamiento del Algoritmo

El algoritmo general, está dividido en tareas secuenciales, tal como se muestra en la figura 3.




Fig.3. Esquema de división de tareas.

## A. Detección de la falta:

Esta tarea busca dar inicio al algoritmo, tras detectar la ocurrencia de un evento en la red. En general, el criterio comúnmente utilizado a este respecto es la condición de que el valor efectivo de la corriente en alguna de las fases del sistema, supere un umbral preestablecido.

En este trabajo se plantea como criterio de detección la superación de un umbral ( $M_{aj}$ ) del "Modulus Máxima" (MM) del detalle 1 (d1) de la TW de las señales de corriente en el dominio modal, es decir:

$$|MM_{d1}(I_\phi)| > M_{aj} \quad (16)$$

Donde:  $\phi = a, b \text{ ó } c$ .

Se define como "Modulus Máxima" (MM), al máximo local del valor absoluto de la transformada para un nivel de detalle específico, en un intervalo de tiempo definido ( $\epsilon, \Delta t + \epsilon$ ).

$$MM = \text{Max}|WT(j,k)|_{t=\epsilon}^{t=\Delta t+\epsilon} \quad (17)$$

Donde  $WT(j,k)$ , es la transformada Wavelet de la señal  $f(t)$  en la escala "j".

La ubicación del MM en un intervalo de tiempo, corresponde al instante de ocurrencia del máximo valor de la transformada en este periodo y su polaridad está relacionada con el sentido del cambio abrupto de la señal. Las ventajas de trabajar con esta definición son, por una parte, la reducción significativa de la cantidad de información extraída de la señal, ya que se reduce a la identificación de singularidades con un solo coeficiente distinto de cero y por ultimo, constituye una herramienta para localizar de manera más precisa el instante (tiempo) de ocurrencia de la singularidad [8]. Un ejemplo para una señal de corriente, se muestra en la Fig. 4.




Fig. 4. MM del detalle 1 de la señal de corriente del modo  $\alpha$ , para una falta A-T.

El valor umbral  $Maj$ , se selecciona en el peor escenario posible, que correspondería a la máxima impedancia de falla ( $Z_f$ ) y a un ángulo de inserción de voltaje, de cero grados.

### B. Clasificación de la falta y selección de las fases involucradas:

En esta tarea se busca obtener como resultado, el tipo de falta existente, así como las fases involucradas en la misma. Como ha sido comentado anteriormente, se va a utilizar una red neural como apoyo en la clasificación, del tipo probabilística.

El esquema de la red, va a tener como entrada, cuatro neuronas, correspondientes a los factores [ $C_A$ ,  $C_B$ ,  $C_C$  y  $C_{Tierra}$ ], donde:

$$C_\phi = c_{\phi 1} + c_{\phi 5}; \text{ con } \phi = A, B, C \text{ y } T. \quad (18)$$

$$Y, \quad c_{\phi i} = \sum_j |d^i_j|^2 \quad (19)$$

Donde los  $d^i$ , corresponden a los coeficientes de detalle, para la fase  $\phi$  y para el nivel de descomposición  $i$ . Es de notar que el término  $C_{\phi i}$ , corresponde a una especie de energía espectral para el nivel de detalle  $i$ , contenido en una ventana de un cuarto de ciclo inmediatamente posterior a la detección del evento.

En resumen, los factores utilizados como entrada para la red de clasificación, poseen información frecuencial para los niveles de detalle 1 y 5.

Cabe resaltar que en este trabajo se utiliza como función wavelet, la daubechies 8 (db8), aplicada a una señal muestreada a 100kHz, que correspondería a 2000 muestras por ciclo para un sistema con frecuencia fundamental de 50Hz, por lo que el detalle 1, según el esquema de multirresolución, contendría la información que se encuentra en el rango de frecuencias de [25-50kHz] y el nivel 5 [1.6 – 3.1kHz].

Para un mejor comportamiento de la red, el vector de entrada es normalizado, utilizando como cantidad base, el mayor valor registrado para ese vector en particular, así:

$$V_C = \left[ \frac{C_a}{C_{base}}, \frac{C_b}{C_{base}}, \frac{C_c}{C_{base}}, \frac{C_{Tierra}}{C_{base}} \right] \quad (20)$$

Donde:

$$C_{base} = \max[C_a, C_b, C_c, C_{Tierra}] \quad (21)$$

Y la salida, corresponde a la clasificación de la falta de tipo binario, con el siguiente esquema:

$$Salida = [FT, FA, FB, FC] \quad (22)$$

Donde los  $F_x$ , toman valores de “0” ó “1”, según esté involucrada en la falta, la tierra, la fase A, la fase B ó la fase C, respectivamente.

### C. Discriminador Direccional de la falta:

En este caso, la metodología utilizada, se basa en el principio de la direccionalidad de la potencia, para determinar la ubicación de la falta, respecto al nudo de medición (detrás o delante).

El principio de esta metodología, se encuentra bien descrito en [9] y la diferencia en la aplicación hecha en el presente trabajo, es el uso del primer pico del “Modulus Maxima” de las señales de tensión y corriente de las fases falladas, para determinar la dirección de la falta. Así, el criterio se basaría sencillamente en la determinación del signo de una “potencia instantánea”, que se calcula como el producto del  $MM_{d1}$  de la tensión por el de la corriente, según se resume en la siguiente ecuación:

$$\frac{MM_{d1}(V_\phi)}{|MM_{d1}(V_\phi)|} \cdot \frac{MM_{d1}(I_\phi)}{|MM_{d1}(I_\phi)|} = D_d \quad (23)$$

Si  $D_d > 0$ , entonces la falta está detrás del nudo.

Si  $D_d < 0$ , entonces la falta está delante del nudo.

### D. Localización de la Falta:

Para la localización de las faltas, se utilizó el método de las ondas viajeras, extrayendo la información relevante mediante la TW y teniendo como apoyo en la identificación, una red neural del tipo RBFNN.

Existen muchos métodos para la localización de faltas en sistemas eléctricos (<http://prof.usb.ve/mmlozano>) y una breve clasificación podría ser la indicada en la siguiente figura.

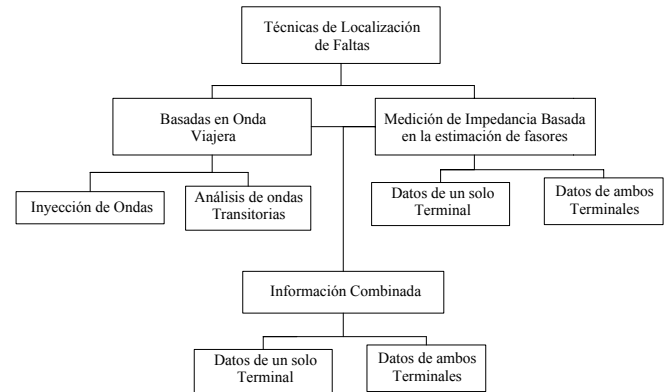


Fig. 5. Clasificación de las técnicas de localización.

En el caso del presente trabajo, se va a utilizar la información de las componentes de alta frecuencia (onda viajera), obtenidas a partir del primer nivel de detalle de la TW (y más específicamente del  $MM_{d1}$ ).

En general, el análisis de ondas viajeras producidas por un evento en el sistema, se realiza en el dominio modal, pues esto simplifica notoriamente la complejidad de los acoples entre fases y el efecto del plano de tierra en la propagación de la onda electromagnética. En este caso se va a utilizar la matriz de transformación de Karrenbauer.

Las señales que preferentemente son utilizadas para este fin, son las de tensión, registradas en un nodo particular del Sistema.

El esquema que muestra de forma simplificada el fenómeno de las ondas viajeras y el efecto de las reflexiones y transmisiones según las condiciones de borde presentes, se muestra en la siguiente figura.

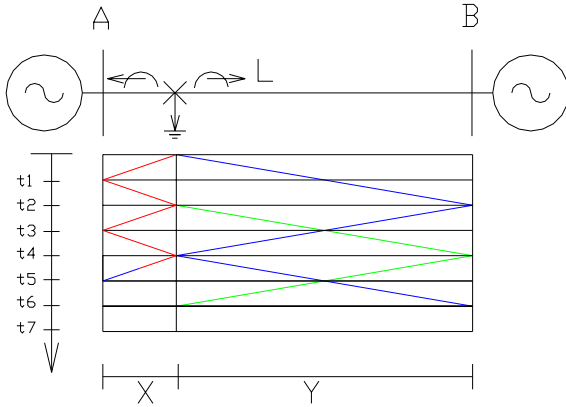


Fig. 6. Diagrama de Laticce, para el caso de Falta 3φ, con X < Y.

En función de dicho diagrama, se pueden obtener las ondas incidentes registradas en los nudos A y B y con dicha información puede calcularse la distancia a la falta desde el extremo 1 (de medición) (X) o desde el nudo B (Y), en base a las siguientes expresiones:

$$X := \frac{v \cdot (t_3 - t_1)}{2} \quad (24)$$

$$Y := \frac{v \cdot (t_6 - t_2)}{2} \quad (25)$$

Donde:

v es la velocidad de propagación de la onda electromagnética para el modo m, utilizado ( $\alpha, \beta \neq 0$ ).

La precisión de la localización bajo esta premisa depende de la exactitud en el registro de dichos intervalos de tiempo. Esto depende de forma significativa de la frecuencia de muestreo y de la detección e identificación precisa de la incidencia de cada señal.

Hay que acotar que los casos donde X > Y ó X < Y, son diferentes y el análisis para la identificación de las ondas que corresponden al viaje en ese intervalo y distinguirlas de las que pueden provenir de las reflexiones en los nodos remotos, no es trivial. En [10], se presenta una forma de resolver en parte el problema, mediante la utilización de funciones de correlación cruzada.

En este caso en particular, se va a utilizar una red neural para que en base a un número considerable de entrenamientos, sea capaz de reconocer el patrón de ondas que se produce en el nodo de medición y en función de éste, establecer la distancia a la falta.

La arquitectura de la red seleccionada, es la siguiente: siete entradas, una capa oculta de 10 neuronas (cantidad seleccionada empíricamente, en función de las pruebas realizadas) y la salida compuesta por una neurona que corresponde a la ubicación de la falta.

El Vector de entrada contiene como información, la posición y polaridad de los primeros siete picos del MM<sub>d1</sub> detectados para el modo  $\alpha$  (la posición está representada en cantidad de veces el paso de muestreo).

$$V_L = [P_1 \cdot X_1, P_2 \cdot X_2, P_3 \cdot X_3, P_4 \cdot X_4, P_5 \cdot X_5, P_6 \cdot X_6, P_7 \cdot X_7]$$

Donde:

P<sub>n</sub> es la polaridad del MM<sub>d1</sub><sup>n</sup> y X<sub>n</sub> es la posición en tiempo (en veces del paso de muestreo), dentro de la ventana de ¼ de ciclo considerada.

Un ejemplo de los vectores de entrada, se muestra en la figura 7.

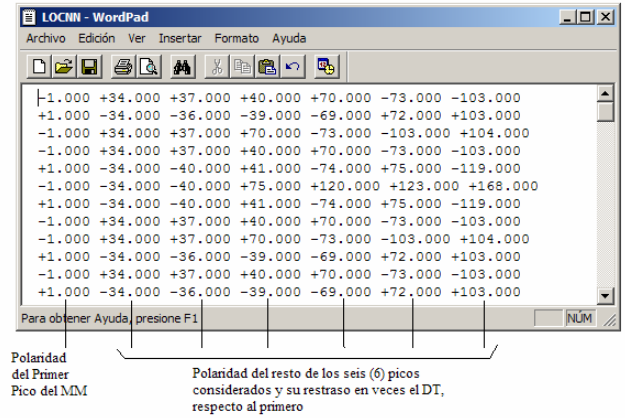


Fig. 7. Archivo con la información del Vector V<sub>L</sub>.

Y el vector de salida, sería directamente la ubicación de la falta en porcentaje de la longitud total.

$$Salida = [L_{falta}(\%)] \quad (26)$$

## 5. Evaluación del Algoritmo

El algoritmo ha sido implementado en la versión 7 de Matlab y para evaluar su funcionamiento ante distintas condiciones y escenarios, se utilizó un sistema esquematizado en el unifilar del figura 8. Dicho esquema corresponde a un sistema de 400kV @ 50 Hz, de cuatro barras. La configuración geométrica de las tres líneas de transporte, es idéntica y está detallada en [1], el MVacc en B1 es de 1GVA y en B4 de 0.7 GVA. El desfase entre las tensiones internas de los generadores G1 y G2, es de 10°.

El sistema fue simulado utilizando el programa de transitorios electromagnéticos ATP/EMTP, modelando de la forma más confiable y completa posible cada uno de los elementos involucrados (las líneas con el modelo de parámetros dependientes de la frecuencia, las características de los Transformadores de intensidad y divisores capacitivos, así como el modelo no lineal del arco de falta).




Fig.8. Sistema considerado para la evaluación del algoritmo.

### A. Escenarios Estudiados:

Los casos considerados para la evaluación del algoritmo, para el sistema particular anteriormente descrito, fueron los siguientes: (un total de 1800 casos)

1. Tipo de falta: Se consideraron los diez tipos de faltas posibles (F3 $\phi$ , F2 $\phi$ -T, F2 $\phi$  y F1 $\phi$ ).
2. Angulo de Inserción del voltaje: 0°, 45°, 90°, 135° y 180°.
3. Impedancia de falta (solo resistiva – Rf): 0  $\Omega$ , 10 $\Omega$  y 100 $\Omega$ .
4. Localización de la falta:
  - a. Externas: en barras B1 y B4.
  - b. Internas: al 0%, 10% , 30; 50%, 80% y 100% de la longitud de línea B2-B3.

### B. Resultados:

#### 1. Detección:

Para la detección, se utilizó el criterio expuesto en la expresión (16). Lo que corresponde en este aparte, es la determinación del parámetro  $M_{aj}$ , para el sistema en estudio. El  $M_{aj}$ , debe cumplir con no ser superado en condiciones normales de operación y debe ser inferior a la peor condición de falta (bajo ángulo de inserción y alta impedancia de falta). El  $M_{aj}$ , seleccionado para este sistema, fue de:  $M_{aj} = 0.05$ .

$$0.027 < M_{aj} < 0.18$$

En la siguiente figura, se muestra la determinación del ajuste, para dos condiciones de las estudiadas.




Fig. 9. Determinación del  $M_{aj}$ , para (a) condición de no falta en el sistema y (b) Falta monofásica (A-T) con  $R_f=100 \Omega$  y ángulo de inserción 45°.

#### 2. Clasificación:

Para la tarea de clasificación, es necesario en una primera etapa, entrenar a la red neural con los 1800 casos planteados. El entrenamiento, se llevó a cabo según el esquema de la Fig. 10.

El error obtenido, al comprobar la respuesta de la red, ante los 1800 casos base de entrenamiento, fue nulo. Para evaluar su capacidad de generalización, se crearon 1800 casos adicionales con valores de variables distintos a los del punto 5.A. Algunos de esos resultados se muestran en

la Tabla I. Igualmente no se obtuvo ningún caso en el que la clasificación no fuera correcta, con el algoritmo de evaluación implementado.

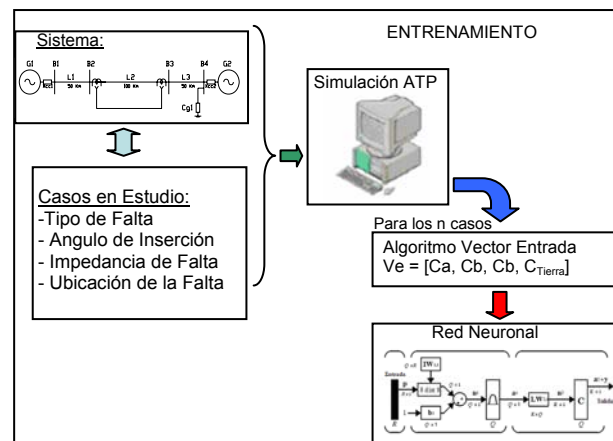


Fig 10. Esquema de generación de casos y entrenamiento de una red neural.

Tabla I. Resultados Tarea de Clasificación

Rf ( $\Omega$ )	Angulo ( $^\circ$ )	Falta	Ca	Cb	Cc	NN*
0	30	FAB	1	0.03	0.99	0110
0	60	FBT	0.21	1	0.23	1010
0	180	FCT	0.22	0.23	1	1001
0	0	FAT	1	0.56	0.23	1100
10	0	FCAT	0.92	0.03	1	1101
10	30	FAB	1	0.99	0.03	0110
100	0	FCA	0.98	0.04	1	0101
10	60	FABC	0.85	1	0.79	0111
100	60	FCT	0.20	0.20	1	1001
0	90	FABT	1	0.95	0.03	1110
10	90	FBCT	0.04	1	0.89	1011
100	90	FBT	0.21	1	0.22	1010

\*Salida de la red neural probabilística [FT,FA,FB,FC].

#### 3. Discriminador Direccional de la falta:

En este caso se trata de comparar las polaridades del producto de MMd1 de tensión e intensidad, según la expresión (23).

En las siguientes figuras, se muestra un caso de falta externa (en dirección inversa), ocurrida en la barra B1 y otra de falta interna (dirección directa), al 50% de L2.

Como se puede comprobar, en general, el criterio establecido permite establecer con bastante claridad la dirección de falta. Solo existen conflictos en aquellos casos donde el ángulo de inserción de la tensión está cercano a 0°, aunque al incluir el modelo del arco, este problema se minimiza.

#### 4.- Localización de la Falta:

La tarea de localización, es tal vez la más complicada de todas, pues depende de muchas variables y es muy sensible a parámetros como altas resistencias de falta, bajos ángulos de inserción y faltas cercanas a la barra de medición.




Fig. 11. Simulación de Falla en 50% L2.




Fig.12. Simulación de Falla en B1.

Todo esto hace que si bien la metodología funciona de forma aceptable para la mayoría de los casos estudiados (con errores inferiores al 5%), hay escenarios como los mencionados en los que definitivamente el algoritmo no trabaja correctamente, obteniéndose errores de prácticamente el 100%. En la tabla II, se muestran algunos de los resultados obtenidos, después de entrenar a la red de base radial con los 1800 casos base y de probarla con los 1800 casos adicionales, de forma similar al algoritmo de clasificación. La ventaja fundamental de utilizar como información para localizar, a las ondas viajeras, es la rapidez con la que puede responder el algoritmo. Por ello y en virtud de la importancia que este tipo de restricción tiene en el mundo de las protecciones, está clara la necesidad de seguir trabajando en el área, pero con la tendencia a plantear algoritmos basados en información combinada, como se ha descrito en la Fig. 5.

## 6. Conclusiones

En este trabajo se describió la aplicación del análisis Wavelet y de redes neuronales, para la protección de líneas de transporte de energía. En base al análisis de la teoría de Wavelets y a la simulación de la protección de líneas, se demuestran las potencialidades y ventajas del análisis Wavelet multiresolución y en particular del "Modulus Maxima", para obtener y analizar las

componentes transitorias de las señales de tensión e intensidad, destacando en estas metodologías el relativo bajo esfuerzo computacional, permitiendo que se empleen como parte de un sistema de protecciones de alta velocidad.

En las diferentes tareas estudiadas, se observó la efectividad de cada uno de los algoritmos y criterios planteados, destacando el caso de clasificación y localización de faltas.

Tabla II. Algunos Resultados, Localización de Faltas

Falta	Ang(°)	Rf (Ω)	Df (km)	NN (Km)	Error (%)
FAT	0	0	10	11.8	17.571
FCT	0	0	10	14.0	39.805
FABT	0	0	10	10.9	8.916
FBCT	0	0	10	13.5	35.275
FCAT	0	0	10	14.6	46.057
FABC	0	0	10	13.1	31.086
FAT	30	10	50	50.5	0.987
FAB	30	10	50	50.1	0.035
FBC	30	10	50	51.5	2.809
FAT	60	100	80	82.6	3.283
FBT	60	100	80	80.7	0.769
FCT	60	100	80	81.4	1.759
FAB	60	100	80	82.0	2.490
FBC	60	100	80	80.8	0.937
FABC	60	100	80	82.6	3.102

## 7. Bibliografía

- [1] Miguel Martínez. "Fault Detection, Classification and Discrimination, Using Complex Wavelets". Power System Protection Conference. Septiembre 2004. Slovenia.
- [2] R. de Castro, H. Díaz, J. Martínez, M. Martínez. "Introducción a la Transformada Wavelet para ingenieros: un enfoque didáctico". 2do Congreso Internacional en Innovación y Desarrollo Tecnológico. Méjico. Noviembre 2004.
- [3] R. de Castro, M. López, J. Martínez, H. Díaz, M. Martínez. "Introducción al análisis wavelet para la protección de redes eléctricas: técnicas y criterios de discriminación". VII Simposio Iberoamericano sobre Protección de Sistemas Eléctricos de Potencia. Méjico. Noviembre 2004.
- [4] Cheong, W.J.; Aggarwal, R.K. "Accurate fault location in high voltage transmission systems comprising an improved thyristor controlled series capacitor model using wavelet transforms and neural network". T&D Conference and Exhibition 2002: Asia Pacific. Vol 2 Oct. 2002. pp:840 – 845.
- [5] C. Sidney Burrus, R. A. Gopinath, H. Guo. "Introduction to Wavelets and Wavelet Transforms". Prentice Hall. 1998.
- [6] H. Yong. "Redes Neurales". Apuntes de clase. Universidad Simón Bolívar. 1999.
- [7] Oleskovicz, M.; Coury, D.V.; Aggarwal, R.K. "A complete scheme for fault detection, classification and location in transmission lines using neural networks". Seventh International Conference on Developments in Power Protection 2001.
- [8] S. Mallat, W. Liang "Singularity Detection and processing with wavelets". IEEE Transactions on information theory. Vol. 38, No 2, Mar. 1992. pp. 617-643.
- [9] Wei Chen; Malik, O.P.; Xianggen Yin; Deshu Chen; Zhe Zhang. "A wavelet-based ultra high speed superimposed voltage directional protection". Conference on Power System Technology, 2002. PowerCon 2002. Vol. 1, Oct. 2002 pp. 300 -303.
- [10] P. Crossley, P. McLaren. "Distance Protection based on traveling waves". IEEE PAS Vol 102, N 9, Sept 1983. pp. 2971-2983.