



INDICE

1	INTRODUCCIÓN	3
2	JUSTIFICACION Y REVISION BIBLIOGRAFICA	5
3	TECNICAS DE ANALISIS	16
3.1	Introducción	16
3.2	Transformada “Wavelets”	17
	3.2.1.- Conceptos Generales	17
	3.2.2.- Transformada Continua Compleja	28
	3.2.3.- Transformada Discreta	30
3.3	Conceptos Básicos sobre las Redes Neuronales	32
	3.3.1.- Introducción	32
	3.3.2.- Neuronas Biológicas	33
	3.3.3.- Modelo de la Neurona Artificial	34
	3.3.4.- Modelo de una Red Neuronal Artificial	37
	3.3.5.- Ventajas y Desventajas de las Redes Neuronales	38
	3.3.6.- Reglas de Aprendizaje	39
	3.3.7.- Tipos de Redes Neuronales	40
	3.3.8.- Perceptrones Multicapas	42
	3.3.9.- Algoritmo Retropropagación	45
	3.3.10.- Algoritmo de Redes de Base Radial	49
	3.3.11.- Redes Neuronales del Tipo Probabilística	51
4	PLANTEAMIENTO DEL ALGORITMO	54
4.1	Introducción	54
4.2	Herramientas Previas	55
	4.2.1.- Línea de Transporte y Onda Viajera	55
	4.2.2.- Transformación Modal	60
	4.2.3.- Modulus Máxima	68
	4.2.4.- Obtención del valor efectivo de una señal, a partir de la descomposición Wavelets	74
	4.2.5.- Estimación de Cantidades Fasoriales para tensiones Y corrientes, utilizando Wavelets	82



4.3	Algoritmo para la detección de faltas	90
4.4	Algoritmo para la clasificación de faltas	97
4.5	Algoritmo para la discriminación direccional de la falta	108
4.6	Algoritmo para la localización de la falta	115
5	APLICACIÓN A UN CASO PRACTICO	136
5.1	Introducción	136
5.2	Descripción del Sistema	136
5.3	Detección de la falta	146
5.4	Clasificación del Tipo de falta	148
5.5	Discriminación de la falta	151
5.6	Localización de la falta	153
6	CONCLUSIONES	165
7	FUTUROS TRABAJOS	168
8	BIBLIOGRAFIA	169
9	ANEXOS	179



**UTILIZACION DE LA TRANSFORMADA “WAVELETS” Y DE TÉCNICAS
DE INTELIGENCIA ARTIFICIAL PARA LA LOCALIZACION DE FALTAS
EN LÍNEAS DE TRANSPORTE DE ENERGÍA**

1.- INTRODUCCION

Una de las grandes áreas de investigación que en los últimos tiempo 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:

- Técnicas de Análisis de Señales (Transformada “Wavelets”).
- Técnicas de Inteligencia Artificial (Redes Neuronales).

También cabe resaltar el hecho de que los trabajos más recientes en el campo de las protecciones, no separan las técnicas de localización, de las de protección, dando nuevos nombres a filosofías y esquemas de protección como la protección “posicional”, la cual por su completo desarrollo del problema, va a ser abarcada en el presente informe.

En conclusión, el presente trabajo va a tratar sobre el estudio de las técnicas modernas de localización de faltas en sistemas de transición aplicando la transformada “wavelets” y redes neuronales en todas las fases importantes del proceso.

El informe está dividido en ocho capítulos, divididos de la siguiente forma: inicialmente se plantea una revisión bibliográfica con la justificación de las técnicas a utilizar; posteriormente, se abarca una introducción técnica sobre los dos métodos de análisis a utilizar (“wavelets” y redes neuronales), para seguidamente desarrollar un algoritmo completo bajo el esquema de protección “posicional” en todas sus facetas desde la detección de la anomalía hasta su localización y por último la aplicación práctica a un caso particular, reducido a dos barras.



2.- JUSTIFICACION Y REVISION BIBLIOGRAFICA

El tema principal de este trabajo se centra en la localización de faltas en sistemas de transporte de energía y específicamente en las líneas de transmisión.

Debe quedar claro que para el desarrollo de los algoritmos de localización, es necesario un conocimiento pleno de las características de la falta. Esto conlleva a la necesidad de un grupo de tareas previas que no se diferencian en nada de las existentes en algoritmos de protección. Estas tareas pueden dividirse de la siguiente manera:

a.- Detección del evento. Debe existir alguna condición o señal que genere el inicio del algoritmo.

b.- Clasificación de la falta. Esta es una etapa muy importante para garantizar una adecuada precisión en la localización y a su vez es vital en sistemas de transporte, especialmente si hay posibilidades de reconexiones monofásicas.

c.- Discriminación direccional. La dirección de la falta debe ser determinada para evitar errores en las órdenes de disparo, según el esquema de protección y es igual de importante para la localización.

d.- Localización. Este punto es común tanto para equipos que necesitan localizar la falta como parte del esquema de protección (localización en línea: ONLINE) o para esquemas independientes de localización para labores de reparación y mantenimiento (localización fuera de línea: OFFLINE).

Como se observa, las tres tareas iniciales, son idénticas tanto para algoritmos en línea, como para los fuera de línea.

Por tanto es claro que el desarrollo de técnicas de análisis y de plataformas de hardware, en el ámbito de las protecciones tiene una repercusión directa en cualquier avance en cuanto a filosofía, esquema o algoritmo en la localización de faltas.

Para tener una idea, en la Fig. 2-1, se indica en forma esquemática el avance en cuanto a plataformas y algoritmos en las protecciones eléctricas.

De ahí puede sacarse como conclusión, que las últimas tendencias están marcadas en cuanto a hardware, por el desarrollo de plataformas basadas en microprocesadores (numérico) y en cuanto a las técnicas, aquellas basadas en transitorios y en el uso de inteligencia artificial.

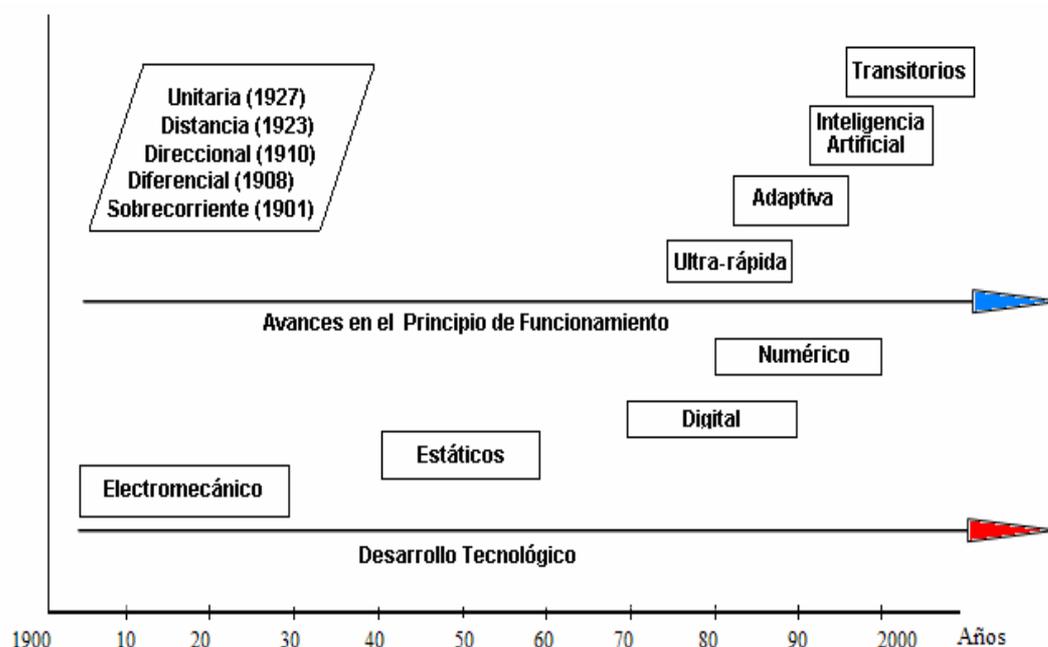


Fig. 2-1. Avance de principio de funcionamiento y tecnológicas de relés de protección [12].

Así que el presente trabajo se va a basar en el uso de dichas técnicas, para las distintas etapas mencionadas anteriormente, con el objetivo claro de lograr la mayor precisión en la estimación de los parámetros de interés y en la confiabilidad de la propuesta para los diferentes escenarios que se pueden presentar.

Para justificar cada uno de los aspectos relevantes a ser desarrollados, a continuación se presenta un breve recorrido bibliográfico que toma en cuenta cada etapa de desarrollo y las técnicas utilizadas. Dicha revisión, se va a centrar en los últimos cinco años.

2.1- Localización de faltas en líneas de transporte de Energía.

La localización ha sido tratada como técnica desde el mismo inicio de la protección de líneas de transporte y es que la protección más conocida como lo es el propio relé de distancia, se basa en la estimación de la ubicación de la falta a partir del cálculo de la relación entre la impedancia vista por el relé, y la impedancia nominal de la línea a proteger. Por tanto, no está de más indicar que la base fundamental de la localización de faltas es la estimación paramétrica de la impedancia de la línea a partir del cálculo fasorial entre las tensiones y corrientes.



Fig.2-2. Falta trifásica en una línea de 115 kV debido a una descarga atmosférica.

Con el avance de la tecnología, se han seguido desarrollando distintas técnicas que en general, podrían ser agrupadas, según la indicación de Kawady en [124], en dos grupos indicados en la Figura 2-3.

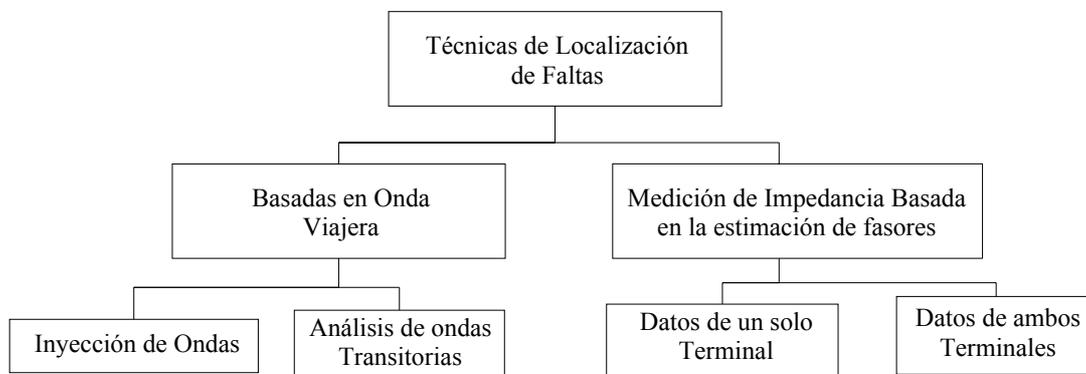


Fig. 2-3. Clasificación de las técnicas de localización [124].

Y adicional a esta clasificación y en base a [118, 127 y 133], se debe incorporar un caso donde se utiliza la información combinada tanto de alta como de baja frecuencia, con o sin la necesidad adicional de la estimación de favores, por lo que se podría modificar y crear la Fig. 2-4.

También hay que indicar que el uso de datos de más de un Terminal tiene inconvenientes como la necesidad de sistemas de telecomunicación y sincronización para su correcta comparación, esto trae un coste adicional no siempre justificado.

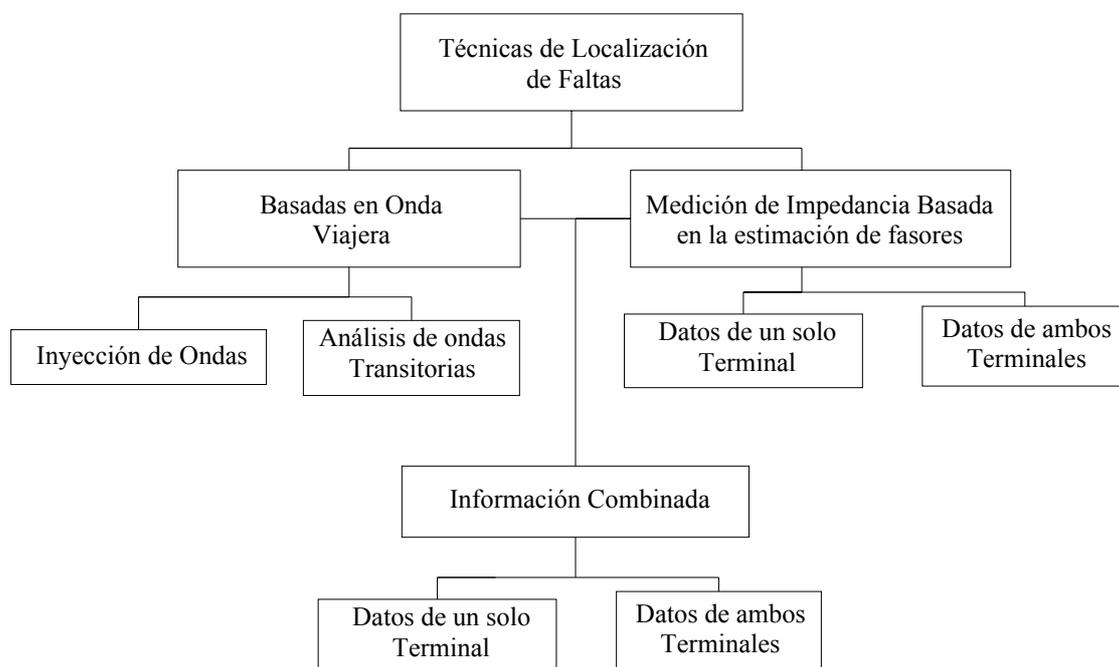


Fig. 2-4. Clasificación de las técnicas de localización.

El problema con las técnicas básicas indicadas en la Fig. 2-3, es que poseen diversos inconvenientes que pueden ser resumidos de la siguiente forma:

- Método de la estimación de la impedancia:
 - Asume variación lineal de la impedancia con la distancia.
 - La impedancia de falta, afecta notoriamente la estimación.
 - La condición de carga.
 - El nivel de cortocircuito de la (s) fuente (s).
 - La topología de la red.



- Método de la onda viajera:
 - Depende fuertemente del ángulo de inserción del voltaje, pues al ser cercano a cero, no se origina onda viajera.
 - Cuando la falta es muy cercana a la barra, es prácticamente imposible estimar la distancia.

Todos estos inconvenientes hacen que cada una de las técnicas por separado no funcionen correctamente en el 100% de los casos que pueden presentarse en condiciones reales de operación.

Por ello, la mezcla o combinación de la información proveniente de la medición de las corrientes y voltajes puede ser de mayor utilidad en conjunto con técnicas de análisis más complejas entre las que podemos destacar las redes neuronales y la transformada wavelets, que agrupan la mayor cantidad de publicaciones en los últimos años.

Hay otras técnicas intermedias como las indicadas en [67, 74] que utilizan para la localización la estimación fasorial por medio de PMU (Phasor Measurement Units) y que intercambian información por medio de sincronización vía GPS. Estas ideas arrojan estimaciones bastante precisas, pero requieren un alto costo de inversión que se justificaría solo en casos puntuales.

Ya centrándose en las herramientas de análisis específicas para la mejor estimación en cada uno de los casos que se han planteado, podrían resumirse en la siguiente lista:



a.- Análisis en Baja Frecuencia:

La mayoría basado en la estimación clásica de la impedancia.

- Esquemas convencionales de estimación fasorial de la impedancia y en función de ella, calcular la distancia de la falta (planos R-X). Estos esquemas son acelerados con algoritmos basados en ventanas adaptivas [44, 45, 86, 87]
- Uso de filtros de Kalman para la estimación fasorial [43, 103].
- Red Neuronal para el ajuste de curvas (estimación paramétrica) [46, 47, 49, 50]
- Red neuronal de base radial o tipo “Backpropagation” sin estimación paramétrica [127].
- Resoluciones matemáticas complejas basadas en operadores dinámicos, para minimizar los tiempos de cálculo [40]
- Uso de filtros de Walsh para la obtención de las componentes fundamentales [66].
- Uso de unidades de medición fasorial en tiempo real (PMU) [67, 74]
- Utilizando la transformada de Wavelets [52, 53, 68]

b.- Análisis en Alta Frecuencia

La mayoría de los artículos revisados, utilizan el principio de las ondas viajeras clásico descrito en [2], pero variando la técnica para extraer la información relevante de las señales, es decir, simplemente cambiando las herramientas.

- Uso de filtros digitales multietapas [12, 42]
- Uso de filtros analógicos y sincronización utilizando GPS [41]
- Uso de redes neuronales auto-organizativas [76]
- Transformada Wavelets [89, 90, 91, 92,93, 94,118, 126, 128]
- Uso de la Morfología Matemática (Procesamiento de señales) [98]
- Redes Neuronales basadas en técnicas estadísticas [96]
- Uso de redes neuronales del tipo “feedforward” o de Base Radial [97,122, 127,134]



c.- Información Combinada:

En este caso se trata de obtener la mayor cantidad de información a partir de relaciones entre las señales de alta frecuencia y las de baja frecuencia que pueden corresponder a favores.

- Estimación de la distribución de voltaje en la línea por medio de las ecuaciones de onda en el dominio modal. [132, 133].
- Solución individual de ambas alternativas (alta y baja frecuencia) y organización de la información arrojada por ambas, utilizando la transformada de Fourier [11,119]
- Utilizando Wavelets en su análisis Multiresolución [118, 121, 128]
- Utilizando lógica difusa en conjunto con la transformada wavelets [128]
- Utilizando redes neuronales en conjunto con la transformada wavelet [121]
- Otras técnicas de inteligencia artificial [122].

Adicionalmente hay que mencionar otros escenarios en los que las líneas de transporte necesitan análisis especiales para su protección (y para la localización de faltas) por la inclusión de elementos entre sus extremos:

- Líneas multiterminales. Estas configuraciones tienen problemas severos para su protección y para la localización de faltas, debido a la presencia de otras ramificaciones que podrían inclusive realimentar la falla.
- Líneas en paralelo. Tienen complicaciones por los acoples homopolares.
- Presencia de elementos de compensación con control o sin control por medio de electrónica de potencia (TSC, FACTS, Compensación en serie)

Cabe resaltar que la mayoría de las publicaciones recientes que involucran estos tópicos utilizan técnicas combinadas de wavelets con redes neuronales [121, 128, 134].



2.2.- Detección, clasificación y discriminación direccional:

Para el resto de fases previas involucradas, se puede realizar la misma clasificación simplificada de técnicas de análisis:

a.- Para el manejo de señales de baja frecuencia:

Una coincidencia, es el planteamiento de un algoritmo pre-falta basado en el uso de ventanas largas (1 ciclo) para la estimación fasorial.

a.1.- Detección:

Los algoritmos complejos que utilizan esquemas adaptivos, necesitan módulos de detección altamente confiables y en general, las tendencias revisadas muestran lo siguiente:

- Detectores de cambio en las magnitudes de corriente o voltaje (comparando muestras actuales con las de 1 ciclo atrás) [19].
- Redes Neuronales basadas en algoritmos genéticos [25].
- Utilizando la transformada de Wavelets [52, 53]
- Uso de unidades de medición fasorial en tiempo real (PMU) [67, 74]

a.2.- Clasificación:

- Redes Neuronales basadas en algoritmos genéticos [25].
- Redes Neuronales basadas en lógica difusa [103]
- Redes Neuronales de base radial [48, 49, 50]
- Utilizando la transformada de Wavelets [52, 53]
- Función de valor incremental [55]
- Uso de unidades de medición fasorial en tiempo real (PMU) [67, 74]

a.3.- Discriminación:

- Uso de las componentes de secuencia positiva de corriente y voltaje, para la estimación del factor incremental de la impedancia [55]
- Uso de unidades de medición fasorial en tiempo real (PMU) [67, 74]



b.- Para el manejo de señales de alta frecuencia:

b.1.- Detección:

- Basado en la magnitud de las señales superpuestas de corriente y/o voltaje [33].
- Uso de filtros digitales multietapas [12, 42], sobre las señales superpuestas de voltaje.
- Uso de la transformada Wavelets Discreta [58, 90, 91, 92, 93, 94]
- Uso de la Morfología Matemática (Procesamiento de señales) [98]
- Uso de redes neuronales [60, 96, 76, 97]

b.2.- Clasificación:

- Utilizando funciones de discriminación modal [33, 2]
- Uso de la transformada Wavelets Discreta [58, 75, 89, 90, 91, 92, 93, 94]
- Redes Neuronales basadas en técnicas estadísticas [60, 96]
- Uso de redes neuronales auto-organizativas [76]
- Uso de los coeficientes modales a través de la transformación de Karrembauer [73, 74]
- Uso de redes neuronales del tipo “feedforward” [97]

b.3.- Discriminación:

- Bajo el principio de la onda viajera claramente descrito en [2]
- Utilizando los componentes modales progresivos y regresivos de cantidades superpuestas de corriente y voltaje
- Uso de redes neuronales basadas en algoritmos genéticos [36]
- Redes Neuronales basadas en técnicas estadísticas [60]
- Uso de la descomposición de frecuencia en sub-bandas, mediante filtros digitales [62]
- Uso de redes neuronales basadas en una función con respuesta finita al impulso (FIRANN) [69]
- Transformada de Wavelets, para obtención de señales superpuestas y así obtener las funciones progresivas y regresivas [70, 71, 89,90, 91, 92, 93, 94]



En conclusión el problema es amplio, dada la gran cantidad de planteamientos existentes, lo que se ha intentado es marcar una tendencia en la que se muestra de forma visible, el uso de las redes neuronales y de las wavelets en la mayoría de los casos.

En el capítulo 4, se desarrollarán en detalle los procedimientos de cálculo descritos en algunos de estos trabajos reseñados de forma simplificada en las listas anteriores

Por otro lado, cada planteamiento tiene dificultades adicionales que deben tomarse en cuenta a la hora de su desarrollo. Dentro de éstos podríamos mencionar como los más clásicos:

- Señales a utilizar (corriente, voltaje o ambas).
- Dominio de la fase, modal o ambos.
- Tipo de matriz de transformación modal a utilizar (Clark, Wedephol, Karrembauer, la compleja de Fortescue, la exacta que diagonalice la línea a proteger, etc).
- Frecuencia de muestreo de la señal.
- Trabajar con las componentes de alta , baja frecuencia o ambas.
- Esquema de la ventana de muestreo a utilizar (adaptiva o fija).
- Técnicas matemáticas a utilizar (DFT, TW, Ecuaciones diferenciales, etc)
- Consideraciones reales de la comunicación como herramienta de información (Intranet, PMU, GPS, etc.).

Adicionalmente, es importante mencionar la herramienta de simulación computacional y la inclusión de los modelos más realistas posibles de los elementos de la red (Líneas de transmisión, Transformadores de Corriente, Transformadores de tensión capacitivos, modelo del arco, etc).



La mayoría de estos componentes han sido estudiados exhaustivamente y poseen modelos relativamente confiables en ciertos rangos de frecuencia; así, el modelo de la línea no podría ser otro que aquel que tome en cuenta la variación de los parámetros con la frecuencia; los transformadores de corriente y voltaje poseen modelos bien definidos en [105 y 106]; el arco primario de faltas con modelos como los descritos y desarrollados en [107, 108, 109, 110, 111]. En caso de la herramienta computacional, lo recomendable es que sea el ATP/EMTP, por su capacidad de manejo de este tipo de maniobras (faltas), por la sencilla incorporación de modelos complejos de ciertos componentes (algunos ya existentes en librerías) y por ser de libre acceso en general.



3.- TECNICAS DE ANALISIS

3.1.- Introducción

En el presente capítulo serán descritos de forma general las herramientas de análisis seleccionadas en para la investigación.

Dentro de los trabajos revisados, el uso de la transformada Wavelet está en auge y pleno desarrollo, dado que se juegan con ciertas funciones y parámetros para lograr distintos objetivos y esto no solo en el ámbito de las protecciones, sino en muchos otros campos de la ingeniería eléctrica (calidad de servicio, sobretensiones y alta tensión).

Así por ejemplo, según la clasificación realizada por módulos o etapas, el uso de las Wavelets se lleva el mayor porcentaje de publicaciones respecto al resto (en el caso de algoritmos basados en transitorios):

a.- Detección

El 43 % de las técnicas recientes, utilizan Wavelets como herramienta. Esto se debe a la alta capacidad de detección de singularidades en una señal.

b.- Clasificación

El 53.3 % de las técnicas recientes, utilizan Wavelets como herramienta.

c.- Discriminación

El 61.5 % de las técnicas recientes, utilizan Wavelets como herramienta.

d.- Localización

El 46.16 % de las técnicas recientes, utilizan Wavelets como herramienta.

De esta manera se justifica plenamente, el uso de la transformada Wavelet en el desarrollo del algoritmo planteado. Adicionalmente hay que indicar la aplicación de técnicas de inteligencia artificial (redes neuronales) como complemento en aquellos casos donde la transformada actuando de forma individual no aporta una solución confiable para todos los escenarios [25, 46, 47, 49, 50, 60, 69, 76, 96, 97, 121, 122, 127, 134].



3.2- Introducción a la Transformada Wavelet y su Aplicación

A continuación se va a presentar una breve introducción al uso y ventajas de la transformada wavelets en su aplicación al temario de los transitorios en sistemas eléctricos.

Esta claro, que la información que se obtiene de las gráficas normales de las señales eléctricas en el dominio del tiempo, no es suficiente.

Algunos aspectos relevantes, respecto a las variaciones de la onda, especialmente ante eventos dinámicos, no pueden ser visualizados ni analizados de forma directa con este formato. En principio, este problema fue solucionado al implementarse la transformada de Fourier, donde se obtiene el contenido frecuencial de la onda analizada. Dicha transformada viene definida por la siguiente función:

$$x(t) = \sum_{k=-\infty}^{\infty} c_k e^{jk(2\pi/T)t}, c_k = \frac{1}{T} \int_T x(t) e^{-jk(2\pi/T)t} dt \quad (3.2.1)$$

Donde:

C_k : son los coeficientes de la transformada de Fourier.

$X(t)$: es la señal a ser analizada.

T : es el período de la función

El factor $2\pi jk/T$ de la función exponencial compleja, solo da información en pasos discretos de frecuencia y se extiende hasta el infinito, por lo cual no se considera un sistema compactamente soportado en tiempo, sino en frecuencia.

El problema con esta transformada, es que no puede ser utilizada en señales no-estacionarias o transitorias, pues al no ser compacto en el tiempo, se analiza la señal de forma global y por lo tanto, solo puede dar información acerca del contenido espectral total de la señal sin localizar éste en el tiempo al cual aparece.

En la Fig. 3-1, se muestra un breve ejemplo tomado de [112]; así la señal mostrada en (a), corresponde a la siguiente función:

$$x(t)=\cos(2\pi*10*t)+\cos(2\pi*25*t)+\cos(2\pi*50*t)+\cos(2\pi*100*t) \quad (3.2.2)$$

Y en (c) se muestra su contenido espectral.

Igualmente, en (b) se grafica una señal cuyos componentes espectrales varían a lo largo del tiempo, de la siguiente manera: En el intervalo (0 - 300 ms) solo está la componente de 100 Hz (senoidal pura), luego en (300 - 600 ms) se introduce una señal de 50 Hz, en (600 - 800 ms) una de 25 Hz y finalmente en el intervalo (800 - 1000 ms) una señal de 10 Hz.

Y sus componentes espectrales (Fourier) se muestran en (d).

Así las componentes espectrales mostradas en (d) coinciden con las de (c). Por lo que es evidente la deficiencia de la transformada de Fourier en dar información acerca del tiempo de ocurrencia de ciertos cambios en la señal.

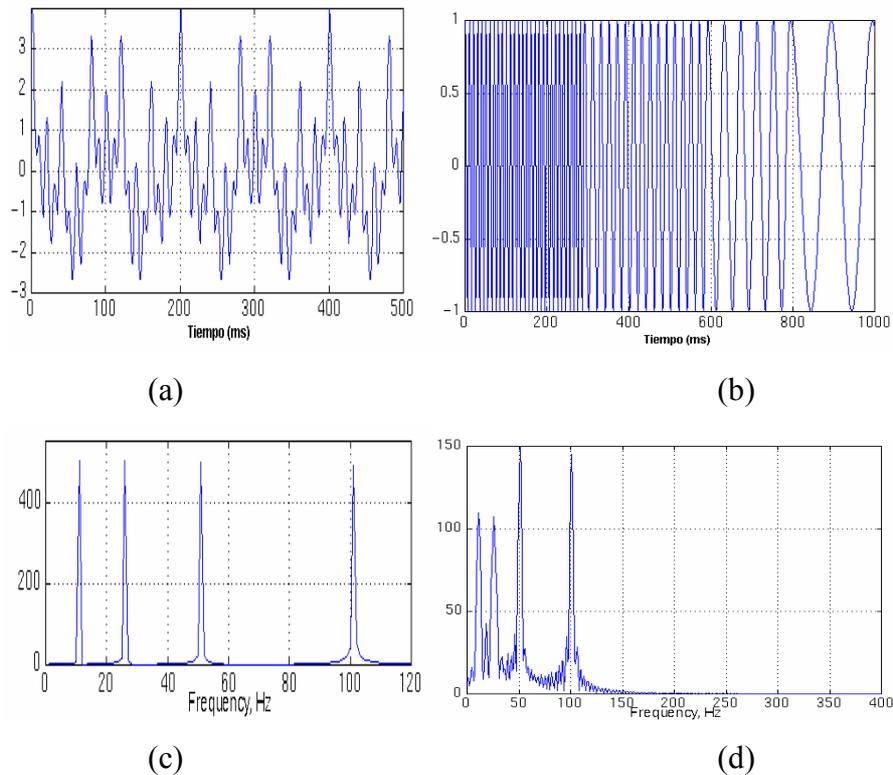


Fig. 3-1. Aplicación limitada de la transformada de Fourier.



En función de estos problemas, se planteó el uso de la Transformada de Fourier de Tiempo corto (“Short Time Fourier Trasforms” – STFT), para permitir mediante el análisis por ventanas, el estudio de señales no estacionarias.

$$S(\tau, f) = \int x(t)w^*(t - \tau)e^{-2j\pi ft} dt \quad (3.2.3)$$

Donde:

X(t) es la señal a descomponer.

$\omega(t)$ es la función ventana.

f es la frecuencia,

τ es el factor de traslación

* es la función de conjugado complejo y

S(τ ,f) es la transformada STFT a ese f y τ , respectivamente.

De forma análoga, la inversa correspondería a:

$$x(t) = \int \int S(\tau, f)w^*(t - \tau)e^{2j\pi ft} d\tau df \quad (3.2.4)$$

El problema de esta formulación es que presenta una resolución constante para todas las frecuencias, pues la ventana es la misma para todo el análisis. Esto implica que si la señal tiene componentes de alta frecuencia, se deberán utilizar ventanas muy pequeñas (soporte compacto en tiempo) y así se logrará buena resolución en tiempo. Sin embargo, esto implica bandas muy anchas en la resolución de frecuencia (mala resolución de frecuencia). Lo equivalente sucede para ventanas muy largas (buena resolución de frecuencia, pero mala de tiempo).

Esta es la principal ventaja de la Transformada Wavelets (WT), pues trabaja variando el ancho de las ventanas y por ende para una serie de resoluciones de tiempo y frecuencia, tal como se muestra en la siguiente figura, la cual resume la resolución que se tiene según el tipo de transformación utilizado.

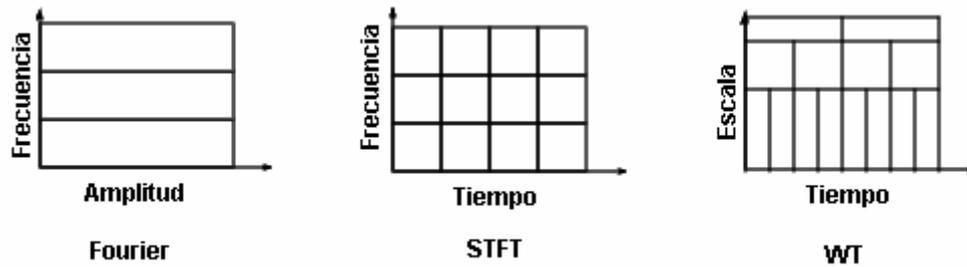


Fig. 3-2. Ventajas de las transformadas en cuanto a resolución en tiempo y en frecuencia.

La WT, trabaja de forma diferente a la STFT, pues primero descompone la señal de interés en bandas de frecuencia y posteriormente la analiza en tiempo.

Se puede plantear la transformada continua de Wavelets, de la siguiente manera:

$$W(a, b) = \frac{1}{\sqrt{a}} \int x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (3.2.5)$$

Donde:

ψ es la función Wavelet Madre.

a y b , son los factores de escala y traslación, respectivamente. ($a > 0$)

$x(t)$ es la función de interés.

$W(a, b)$, es la transformada continua de $x(t)$ ó CWT.

La función $\psi(t-b/a)$, puede interpretarse como la misma función ψ , trasladada y escalada en a y b , por lo que la ecuación (3.2.5), podría describirse, como:

$$W(a, b) = \int x(t) \psi_{(a,b)}^*(t) dt, \quad (3.2.6)$$

Donde:

$$\psi_{(a,b)}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) \quad a > 0, b \in \mathcal{R} \quad (3.2.7)$$



La inversa, sería:

$$x(t) = \frac{C_\psi}{a^2} \int_{a>0} \int_b W(a, b) \psi^* \left(\frac{t-b}{a} \right) da \cdot db \quad (3.2.8)$$

Donde C_ψ son parámetros constantes que dependen de ψ .

Al término en (3.2.7), $\psi_{(a,b)}$, se le denomina función base y debe cumplir las condiciones de admisibilidad: de soporte finito (“small”) y de naturaleza oscilatoria (“wavy”); de ahí el nombre Wavelet (small-wavy) u onda pequeña, ondita, etc.

El problema de la CWT, es que dada una señal $x(t)$, solo se obtiene la información en frecuencia para un factor de escala dado. Por lo que es necesario repetir dicho proceso tantas veces como se justifique, variando la escala.

Este análisis tiene un alto costo computacional que puede ser reducido, mediante la transformada discreta (DWT) y el análisis Multiresolución (MRA).

Para la obtención de la Transformada Discreta de Wavelet (DWT), los parámetros a y b deben ser discretizados. Por ejemplo, si se toma $a=2^j$ y $b=2^j k$, como la planteada por Daubechies (base diádica) , se obtiene como función base:

$$\psi_{(j,k)}(t) = 2^{-j/2} \psi(2^{-j} t - k) \quad (3.2.9)$$

La ventaja podría ser vista en función de la siguiente figura, que tiene que ver con los pasos de resolución en tiempo – escala (Fig. 3-3).

Se observa que en la Fig. 3-3-a, los pasos de variación de frecuencia son constantes, mientras que los de la Fig. 3-3-b, son en potencias de 2 (escala diádica).

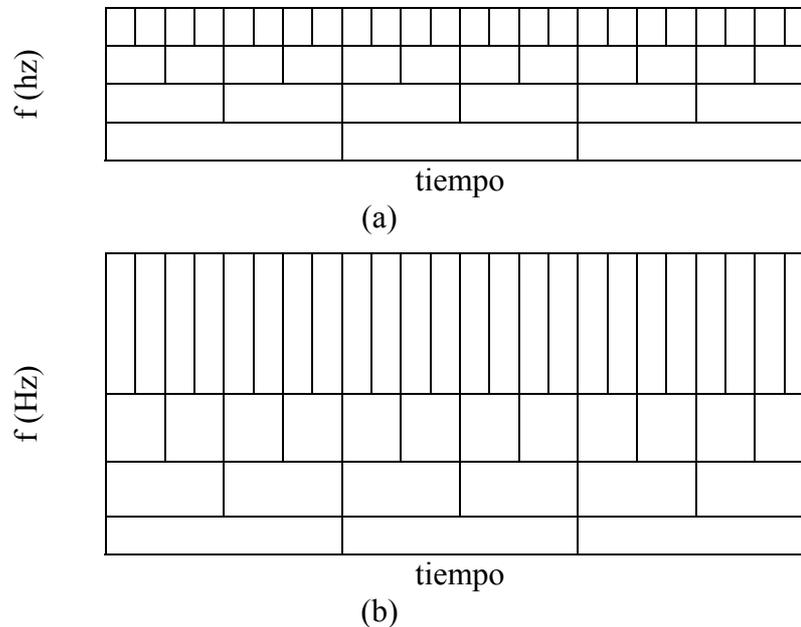


Fig. 3-3. Variación tiempo – frecuencia o tiempo – escala, (a) Transformada continua (CWT) y (b) Transformada Discreta con base diádica.

Para simplificar el cálculo de los coeficientes y términos de la DWT, Mallat planteó la aplicación del análisis multiresolución (MRA), en base a filtros pasa bajos $h(n)$ y pasa altos $g(n)$, que se aplican de forma iterativa. El esquema diagramático de descomposición, se muestra en la Fig. 3-4.

$$y_{high}[k] = \sum_n x[n] \cdot g[2k - n] \quad (3.2.10)$$

$$y_{low}[k] = \sum_n x[n] \cdot h[2k - n] \quad (3.2.11)$$

Donde:

$$h[N - 1 - n] = (-1)^n g[n] \quad (3.2.12)$$

Este cálculo puede realizarse matricialmente a partir de los coeficientes $g(n)_i$, como se plantea en [89].

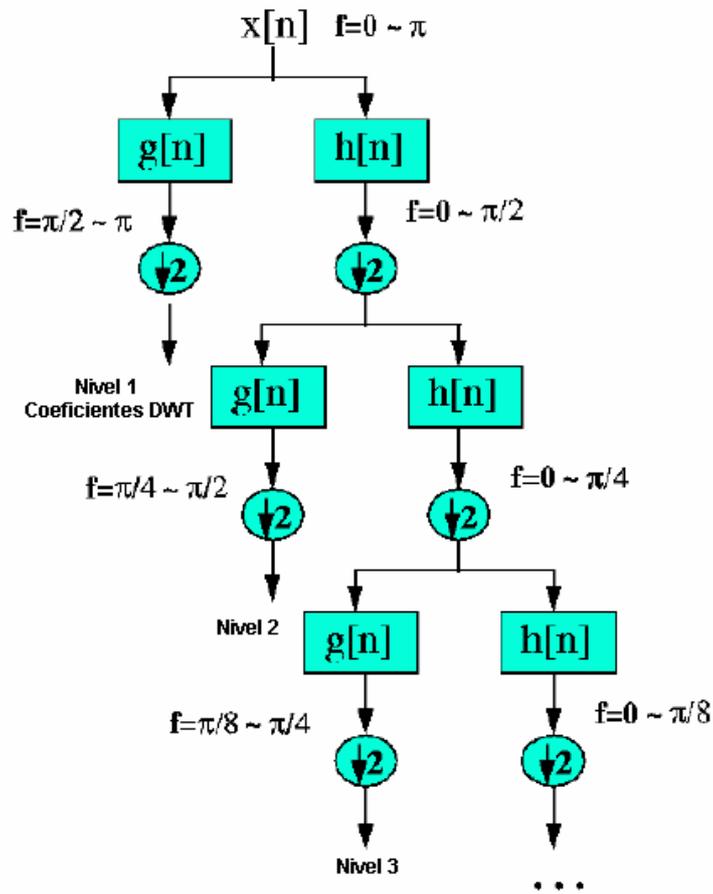


Fig. 3-4. Esquema de la descomposición por el análisis multiresolución.

Existen otros tipos de las Wavelets, así que en general se podrían clasificar como:

- Trasformada continua,
- Transformada continua compleja,
- Trasformada Discreta,
- Wavelets Packets,
- Multi-Wavelets,

Cada uno de estos tipos, pueden ser analizados de forma exhaustiva y sacarle las ventajas y desventajas según las aplicaciones particulares. Al final de esta sección, serán descritas con mayor detalle, las transformadas que van a ser utilizadas: la transformada continua compleja de Morlet y la transformada discreta de Daubechies.

De hecho en Ingeniería eléctrica se puede encontrar toda una variedad de aplicaciones en donde se utilizan distintos tipos de Wavelets. En general, la mayoría de los trabajos realizados, se basan en la transformada discreta y más concretamente en MRA.

Otro grupo especialmente ligado al grupo de protecciones, está empezando a utilizar la transformada continua compleja, por su poder para la obtención de fasores y eliminación de ruido y es precisamente la que va a ser utilizada en este trabajo.

Y pocos se basan en Wavelet packets, cuyas ventajas se pueden resumir en la Fig. 3-5.

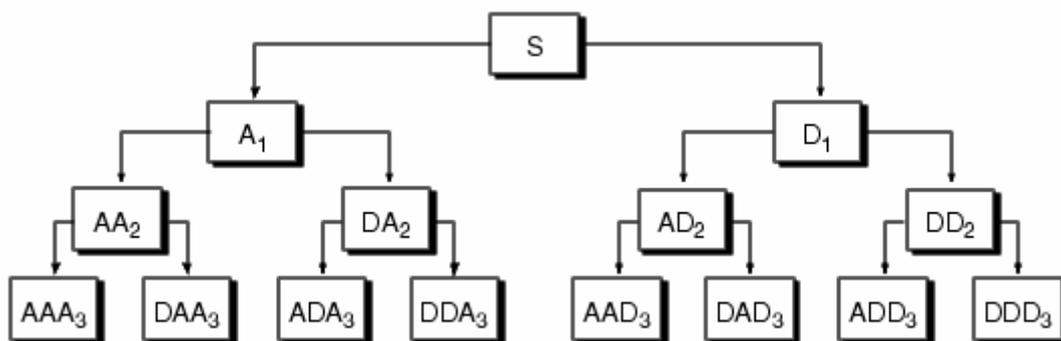


Fig. 3-5. Descomposición de la señal basada en Wavelet Packet. A: filtro pasabajo y D: filtro pasa alto.

En la Fig. 3-6, se denota que la diferencia fundamental entre DWT y Wavelet packet (WP), es la resolución en frecuencia por nivel de descomposición. En DWT, la descomposición es en potencia de 2, mientras que la WP es uniforme.

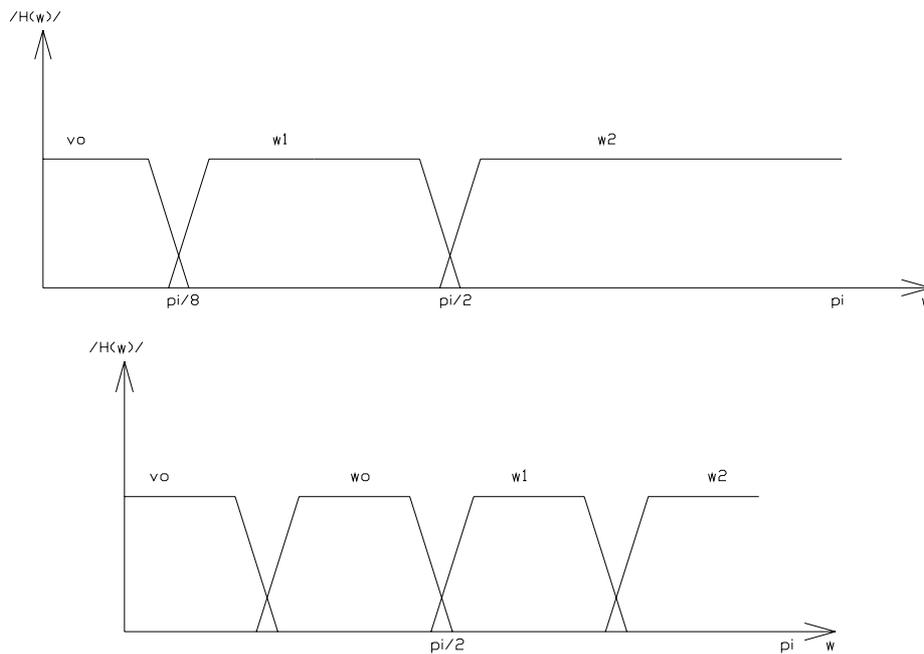


Fig. 3-6. Resolución en frecuencia según el modelo wavelets utilizado. (a) DTW y (b) Wavelet Packet.

No se conocen a la fecha publicaciones ligadas a Multiwavelets aplicadas a la localización o a análisis de calidad de ondas en ingeniería eléctrica.

Otro campo importante está ligado al uso de la wavelet como una función base de una red neuronal, dando resultados positivos en el reconocimiento de patrones en ambientes de alta dispersión.

En definitiva, el uso de las wavelets se resalta en su capacidad de distinción de singularidades en las señales a analizar como lo reseña [113].

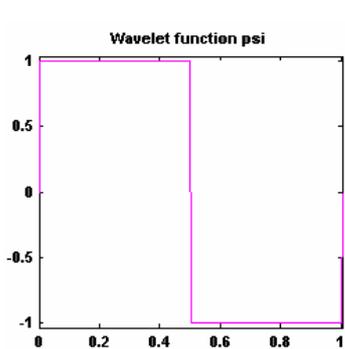
En este capítulo no se ha entrado en detalles matemáticos de la herramienta; sin embargo, las fuentes utilizadas presentan un mayor desarrollo [112, 114, 115].

Por último, se van a mencionar las distintas Wavelet madre existentes (Fig 3-7):

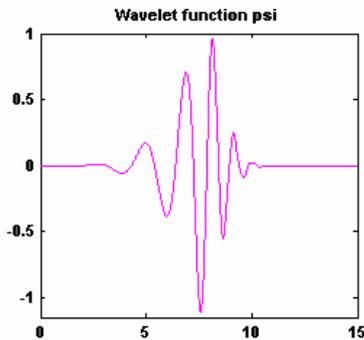
- Haar.(a)
- Daubechies (b)
- Symlet (c)



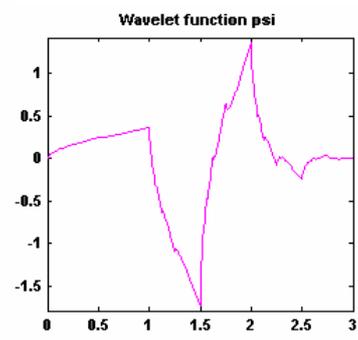
- Coiflets (d)
- Bior-Splines (e)
- Reverse – bior (f)
- Meyer (g)
- Dmeyer (h)
- Gauss (i)
- Sombrero Mejicano (j)
- Morlet (k)
- Gaussian Compleja (l)
- Morlet Compleja (m)
- Shannon (n)
- B-Spline frecuencial (o)



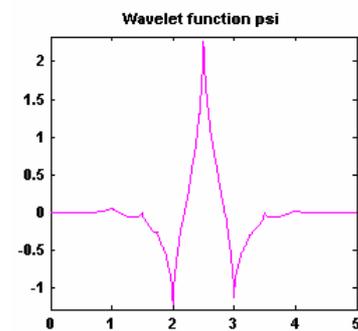
(a) – haar 5



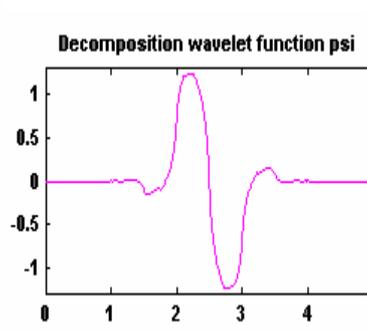
(b) – db8



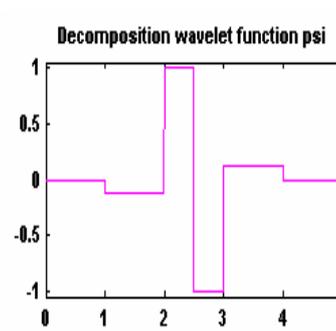
(c) – sym 2



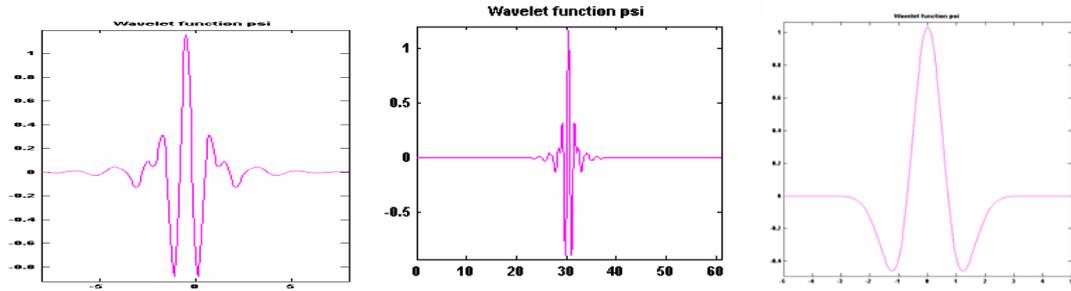
(d) – coif 1



(e) – bior 1.3



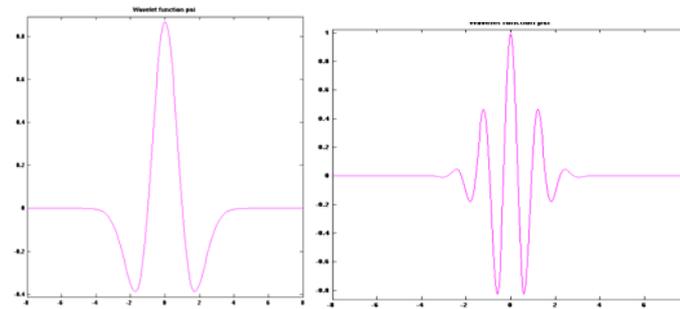
(f) – rbio 1.3



(g) – meyr

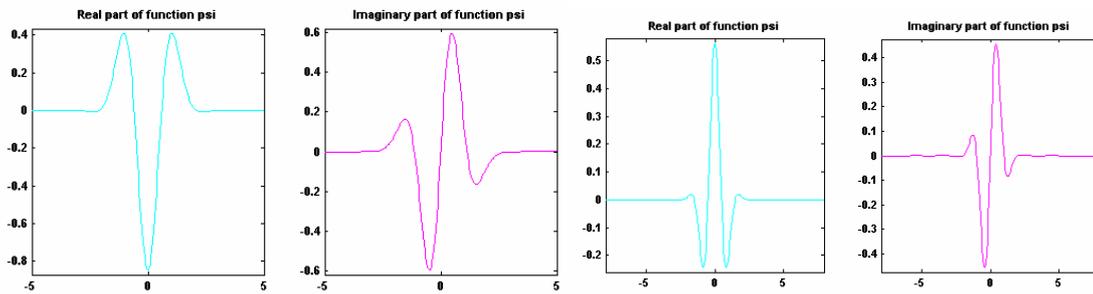
(h) – Dmeyr

(i) - gau 2



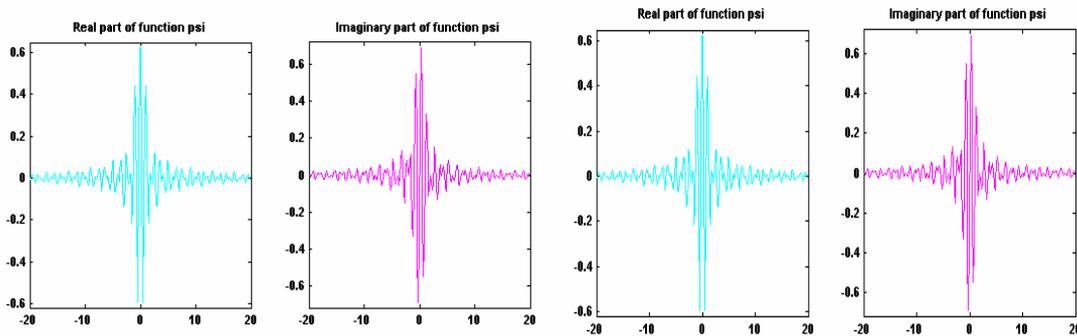
(j) – mexh

(k) – morl



(l) – cgau

(m) – cmor 1-0.5



(n) - shan 1-0.5

(o) - fbsp 1-1-0.5

Fig. 3-7. Algunas gráficas de las funciones madres típicas.

Estas funciones tienen ciertas propiedades que pueden ser ventajosas a la hora de justificar su uso; por ejemplo, su comportamiento en frecuencia $\Phi(\omega)$, que no es más que: $\Phi(\omega) = FT(\psi)$. En las últimas aplicaciones se ha prestado especial atención al hecho de su simetría en frecuencia y en este grupo, caen: Morlet, Sombrero Mexicano, Meyer, Haar y B-Spline (Fig. 3-8).

También es importante si son compactamente soportadas ortogonales o biortogonales.

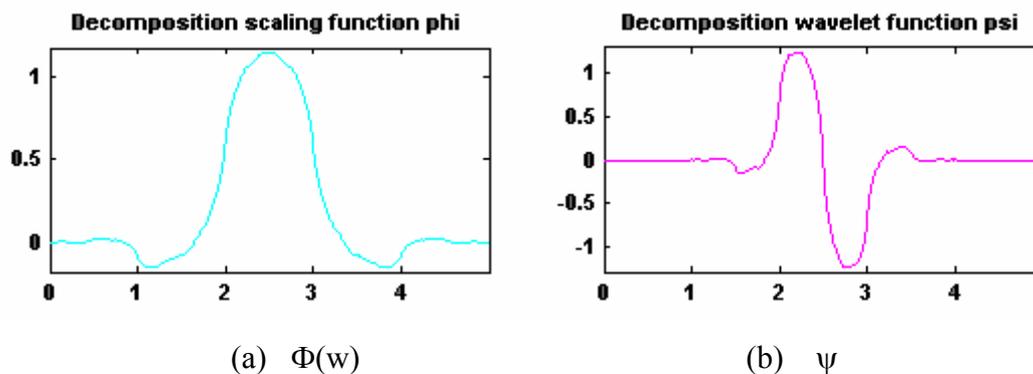


Fig. 3-8. Simetría en frecuencia de la B-Spline 1.3.

En el trabajo desarrollado, se utilizaron básicamente dos tipos de wavelets:

a. Transformada Continua Compleja de Morlet:

La función madre de Morlet en su versión compleja, viene definida de la siguiente manera:

$$\psi(x) = \sqrt{\pi f_b} e^{2i\pi f_c x} e^{-\frac{x^2}{f_b}} \quad (3.2.13)$$

Donde:

f_b , es el ancho de banda, y

f_c , es la frecuencia central de la función.

En la Fig. 3-9, se representa la respuesta oscilatoria con los parámetros de ajuste indicados.

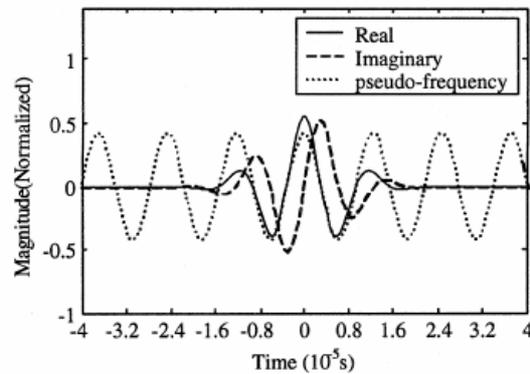


Fig. 3-9. Wavelet Morlet Compleja, con $F_b = 1.25 \times 10^{-5}$; $F_c = 1$ [90].

La ventaja de trabajar con este tipo de transformaciones es que la función madre (B-Spline o C-Morlet – Fig. 3-10), tienen la propiedad de ser simétricas en frecuencia y bi-ortogonales.

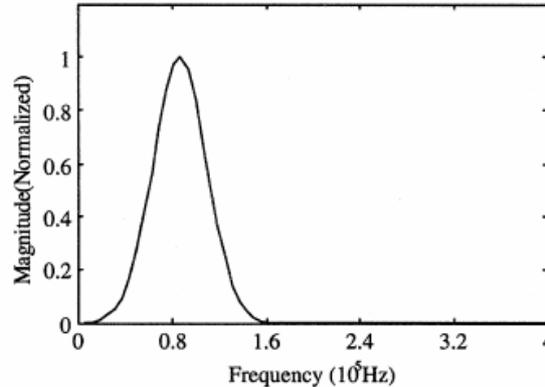


Fig. 3-10. Respuesta en frecuencia de la Wavelet Morlet Compleja [90].

La conveniencia de utilizar esta función, radica en diversas ventajas que pueden ser numeradas a continuación y que han sido presentadas en [68, 90, 100]:

- Al ser compleja permite calcular de forma sencilla las cantidades fasoriales, con las relaciones entre las componentes reales e imaginarios. $J = (I_{\text{real}} + j I_{\text{img}})$
- Es más sensible que el resto de funciones para la detección de singularidades en la señal a analizar y más utilizando lo que se ha denominado una función



combinada que no es más que la mezcla de factores determinados en la transformada. Por ejemplo, en el trabajo se va a utilizar como detección de singularidades, la siguiente función combinada (CI):

$$CI = WTR * WTRIPH \quad (3.2.14)$$

Donde:

$$WTRIPH = |WTR| * |WTI| * WTPH \quad (3.2.15)$$

$$WTPH = \tan^{-1} (WTI/WTR) \quad (3.2.16)$$

WTR: es la componente real de la transformada compleja.

WTI: es la componente imaginaria de la transformada compleja.

b. Transformada Discreta de Daubechies (MRA):

Este tipo de Funciones no tienen una expresión explícita, excepto la db1, que corresponde a la función de Haar. La cual puede ser definida de forma discreta de la siguiente manera:

$$\psi(x) = 1, \quad \text{if } x \in [0, 0.5[\quad (3.2.17)$$

$$\psi(x) = -1, \quad \text{if } x \in [0.5, 1[\quad (3.2.18)$$

$$\psi(x) = 0, \quad \text{if } x \notin [0, 1[\quad (3.2.19)$$

$$\phi(x) = 1, \quad \text{if } x \in [0, 1] \quad (3.2.20)$$

$$\phi(x) = 0, \quad \text{if } x \notin [0, 1] \quad (3.2.21)$$

Sin embargo, para cualquier N mayor que 1, el cuadrado del modulo de la función de transferencia h es explícita y relativamente sencilla de expresar:

Si se define,



$$P(y) = \sum_{k=0}^{N-1} C_k^{N-1+k} y^k \quad (3.2.22)$$

Donde C_k^{N-1+k} corresponde a los coeficientes binomiales, entonces:

$$|m_0(\omega)|^2 = \left(\cos^2\left(\frac{\omega}{2}\right) \right)^N P\left(\sin^2\left(\frac{\omega}{2}\right) \right) \quad (3.2.23)$$

Donde:

$$m_0(\omega) = \frac{1}{\sqrt{2}} \sum_{k=0}^{2N-1} h_k e^{-ik\omega} \quad (3.3.24)$$

Donde N, denota el subíndice del tipo de función (db N).



3.3.- Conceptos básicos sobre las redes neuronales (RNA)

3.3.1.- Introducción:

Una de las técnicas que en la actualidad se usa para predecir o estimar distintas variables a partir de ciertos parámetros de entrada, son las redes neuronales. Diversos trabajos como los revisados en el capítulo anterior, han demostrado los siguientes resultados [139, 140, 141]:

- 1.- En el problema de estimación de variables, se pueden conseguir errores promedios menores al 5 % para un sin fin de aplicaciones; dependiendo de una correcta selección de las variables influyentes en el proceso y de un entrenamiento adecuado.
- 2.- Su aplicación es sencilla.
- 3.- Un adecuado y continuo entrenamiento, puede adaptar la red a los cambios que pudieran presentarse en el sistema, indicando características dinámicas y adaptivas.

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 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 predictiva usada en la actualidad. En el capítulo del desarrollo de los algoritmos se entrará en detalle en cuanto a los aspectos tomados en cuenta para la selección tanto de las arquitecturas como en particular de las variables de entrada, según su importancia y relevancia para la tarea necesaria (clasificación o localización de la falta detectada).

La red neuronal como herramienta de predicción o estimación, se entrena con los datos históricos (patrones de entrada/salida, conocidos) que le permita ir ajustando una



serie de números (memoria, pesos o constantes usadas para enlazar la entrada con la salida) hasta lograr la respuesta deseada.

En la actualidad existen varios tipos de configuraciones o estructuras relacionadas con redes neuronales. Sin embargo la mayoría de los trabajos previos a este, han adoptado para estimar ciertas características asociadas a las faltas eléctricas, la red multicapas, la razón de ello se debe a su sencillez estructural y a su fácil uso y rápido entrenamiento mediante el método de “backpropagation”; Sin embargo, esto no es generalizable y se pueden encontrar cualquier cantidad de aplicaciones individuales con muchos tipos de arquitecturas de las RNA (probabilísticas, auto-organizativas, vecino más cercano, de base radial, etc).

3.3.2.- Neuronas biológicas:

El cerebro humano recibe señales o estímulos de muchas fuentes y las procesa a manera de crear una respuesta apropiada al motivo de su excitación, para ello el cerebro cuenta con millones de neuronas que se interconectan para conformar una red neural. Estas redes ejecutan las millones de instrucciones necesarias para mantener una vida normal. [139, 140]

Las neuronas son las células que forman la corteza cerebral de los seres vivos, y constituyen una unidad de procesamiento de información fundamental para la operación de una red neuronal (RN). Cada una esta formada por tres elementos llamados: cuerpo, axón y dendritas; tal como se ilustra en la figura 3-11.[140]

Las dendritas están formadas por una estructura de filamentos muy fina que rodean el cuerpo de la neurona. El axón es un tubo largo y delgado que se ramifica en su extremo en pequeños bulbos finales que casi tocan las dendritas de las células vecinas. Por último, las sinapsis son las unidades que sopesan las interacciones entre las neuronas.

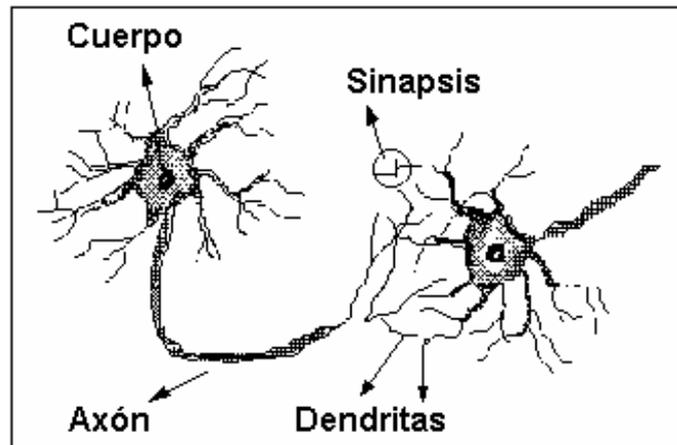


Figura 3-11. Dibujo de una neurona biológica.

Las neuronas, al igual que las demás células del cuerpo, funcionan a través de impulsos eléctricos y reacciones químicas. Los impulsos eléctricos que utiliza una neurona para intercambiar información con las demás ingresan por las dendritas, viajan por el axón, que hace contacto con las dendritas de la neurona vecina mediante la sinapsis.

Las conexiones sinápticas pueden excitar o inhibir la señal que transmiten. Una sinapsis muy utilizada tiende a reforzarse y a ser cada vez más eficiente en la transmisión; mientras que otra de poca utilidad puede ir disminuyendo su eficiencia, y eventualmente, desaparecer. Estas conexiones definen una red de flujo de señales en el cerebro que son la base de funcionamiento del mismo. Se puede afirmar que, dado que todas las neuronas son básicamente iguales, el “conocimiento”, esta representado de alguna manera en las conexiones sinápticas.

3.3.3.- Modelo de la neurona artificial:

Siguiendo la definición y funcionamiento de la neurona natural, se puede plantear un modelo en diagrama de bloques tal como se muestra en la figura 3-12. Este modelo conforma el diseño básico de una red neuronal artificial. En él se pueden apreciar tres elementos constitutivos:

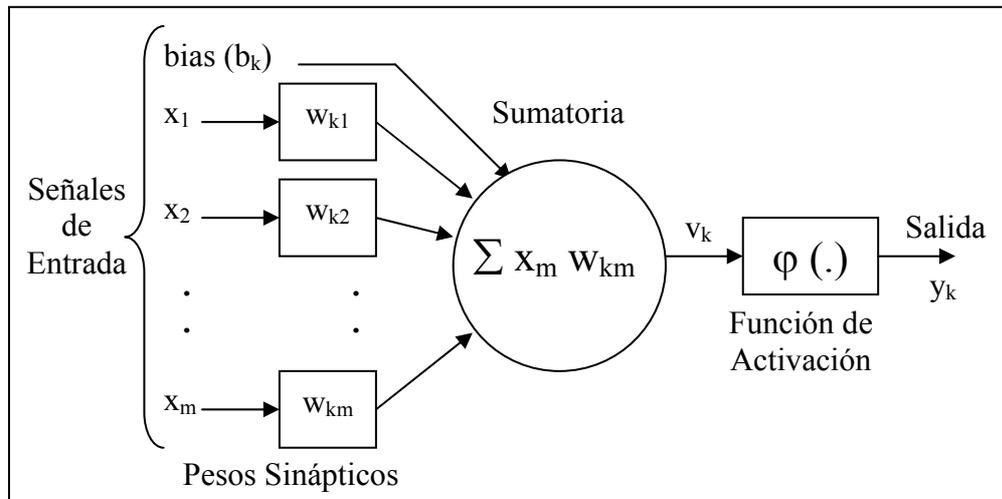


Figura 3-12. Modelo una neurona artificial.

a.- Un grupo de sinapsis o enlaces de interconexión, que caracterizan cada entrada a través de la multiplicación de la misma con un valor, el cual se denomina peso. Este representa la eficiencia de la unión sináptica en la transmisión de la información. Los pesos se denotan con la letra “w”. Específicamente, una señal x_j antes de ingresar a la neurona k será multiplicada por el peso sináptico w_{jk} .

b.- Un sumador que realiza la combinación lineal de las señales provenientes de las respectivas sinapsis de la neurona.

c.- Una función de activación, cuya tarea es limitar la amplitud de la señal de salida de la neurona, a un rango de valores finitos. Típicamente, los rangos normalizados de las amplitudes de las señales de salida son los intervalos **(0,1)** y alternativamente **(-1,1)**.

El modelo propuesto en la figura 3-12, incluye una entrada externa que se denomina tendencia o bias, y esta denotada por b_k . Este parámetro adicional produce el efecto de añadir una cierta tendencia en los datos a la entrada de la función de activación, y permite trasladar dicha función a la región de interés según sea la aplicación.



En términos matemáticos, se puede describir una neurona k mediante las siguientes ecuaciones:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (3.3.1)$$

$$v_k = u_k + b_k \quad (3.3.2)$$

$$y_k = \varphi(v_k) \quad (3.3.3)$$

Donde:

x_1, x_2, \dots, x_m son las señales de entrada

$w_{k1}, w_{k2}, \dots, w_{km}$ son los pesos sinápticos que unen la salida de la neurona k con las entradas de las neuronas $1, 2, \dots, m$.

u_k es una combinación lineal de las señales de entrada sopesadas por los respectivos pesos sinápticos.

b_k es el bias.

v_k es el potencial de activación de la neurona k .

$\varphi(\cdot)$ es la función de activación.

y_k es la señal de salida de la neurona.

La función de activación es uno de los parámetros más importantes dentro del modelo de la neurona, ya que define la salida de una neurona en términos de su potencial de activación. La función sigmoideal es el tipo de función de activación usada con mayor frecuencia para las aplicaciones de la RNA. Su nombre se debe a la forma de **S** que presenta su gráfica (ver figura 3-13), y está definida por una función estrictamente creciente, no lineal y diferenciable, condiciones deseables para el proceso de entrenamiento de la red. Además, la condición de diferenciable es necesaria para que se pueda aplicar la rutina de entrenamiento basado en las arquitecturas de retropropagación, de base radial, etc.

Por otra parte las funciones sigmoideales de mayor uso en la literatura son la función sigmoideal logarítmica (representada en la figura 3-13), definida matemáticamente por $\varphi(\cdot) = 1/(1 + e^{-a \cdot v})$, donde 'a' representa la "pendiente" de la curva; y la función sigmoideal tangencial, definida matemáticamente por

$\varphi(v) = a \tanh(bv)$, donde ‘a’ y ‘b’ son constantes positivas. Aunque estas dos funciones sólo difieren en la escala y en la simetría alrededor de cero, se ha comprobado experimentalmente que la sigmooidal tangencial ofrece una mejor estabilidad numérica en el entrenamiento de la RNA.

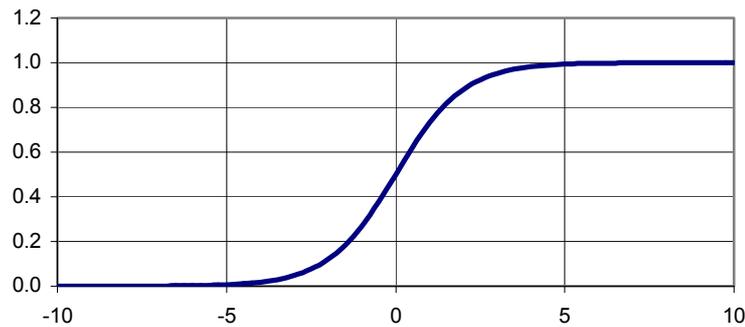


Figura 3-13. Función de activación sigmooidal.

3.3.4.- Definición de una Red Neuronal Artificial:

Las redes neuronales artificiales son dispositivos o software desarrollados en base a los modelos y estructuras neuronales del cerebro humano. A través de las neuronas o unidades de procesamiento son capaces de almacenar conocimiento por experiencia y hacerlo disponible para su uso. Es decir, están diseñados para desarrollar una determinada tarea de forma similar a la cual la ejecutaría el cerebro humano.

Entre las principales tareas y funciones que realizan las RNA se encuentran: la percepción, asociación, reconocimiento y clasificación de patrones, estimación de funciones, comprensión de datos, entre otras. [139, 140]



3.3.5.- Ventajas y Desventajas de las Redes Neurales:

Debido a la semejanza en el funcionamiento de las RNA con el cerebro, esta herramienta computacional nos ofrece las siguientes ventajas:

a.- Aprendizaje. Tienen la capacidad de aprender de los datos que se le presentan, con la cual pueden capturar desde las relaciones más sutiles, hasta las más complejas. Esta capacidad estará definida por la topología de la RNA y el método de aprendizaje utilizado.

b.- No-linealidad. Una RNA puede ser lineal o no. Esta es una gran ventaja, que le permite a las RNA capturar interacciones complejas entre las variables de entrada de un sistema. La no-linealidad es una propiedad extremadamente importante, si los sistemas responsables de la generación de información son inherentemente no-lineales.

c.- Pueden generalizar. Son capaces de manejar las imprecisiones e incertidumbres que aparecen al procesar información que conserva poco parecido con la disponible en su entrenamiento.

d.- No son algorítmicas. No se programan haciéndoles seguir una secuencia predefinida de instrucciones. Las RNA generan sus propias “reglas”, para asociar la respuesta a su entrada, es decir, aprende por ejemplos y de sus propios errores.

e.- Adaptabilidad. Tienen la capacidad de ajustarse al cambio en las condiciones de operación. Por lo tanto, una red neuronal entrenada para operar en un ambiente específico puede ser reentrenable para adaptarse a cambios en las condiciones de operación.

f.- Son estructuras altamente paralelas distribuidas. Sus numerosas operaciones independientes pueden ser ejecutadas simultáneamente. Son ésta y la habilidad de generalización, las dos capacidades de procesamiento de información que hacen posible que la RNA resuelva problemas complejos que normalmente serian intratables.



Estas ventajas son resumen de algunas características del cerebro, tales como: la alta tolerancia a fallas, la flexibilidad, la capacidad de aprender con rapidez y generalizar, la alta velocidad de procesamiento, y el buen manejo de información ruidosa e inconsistente. Ellas han hecho de las RNA una herramienta computacional multidisciplinaria, centrada principalmente en disciplinas como matemáticas, estadística, física, neurociencias, ciencias de la computación e ingeniería, entre otras. Poseen múltiples aplicaciones en diversos campos como la modelación, análisis de series de tiempo, reconocimiento de patrones, procesamiento de señales, control, ... [140]

3.3.6.- Reglas de Aprendizaje:

Las RNA son capaces de almacenar conocimiento a través de la experiencia. El conocimiento es adquirido por la RNA de su ambiente a través de un proceso de aprendizaje. El aprendizaje también sirve para mejorar el desempeño de la red, ya que mediante el reentrenamiento, se le permite a la red neural adaptarse a cambios en las condiciones de operación. Así, podemos definir el aprendizaje como un proceso mediante el cual los parámetros libres de una RNA (pesos sinápticos y niveles de bias), son adaptados a través de un proceso de estimulación producido por el ambiente en el cual la RNA está envuelta.

Existen dos tipos de aprendizaje:

a.- Aprendizaje supervisado: En este tipo de aprendizaje se le proporciona a la red tanto los datos de entrada como los datos de la salida correcta. La RNA ajusta sus pesos tratando de minimizar el error a su salida, el cual se define como la diferencia entre la señal de salida correcta y la actual. Se aplica en tareas como: reconocimiento de patrones, predicción de series temporales y aproximación de funciones.

b.- Aprendizaje no supervisado. Este se presenta cuando a la red se le proporcionan únicamente los estímulos, y la red ajusta sus interconexiones basándose en



sus estímulos y la salida de la propia red. El proceso de aprendizaje consiste en encontrar regularidades estadísticas en los datos de entrada, y así poder especificar clases de las salidas automáticamente por sí solo.

Las leyes de aprendizaje determinan como la red ajustará sus pesos utilizando una función de error o algún otro criterio. La ley de aprendizaje adecuada se determina basándose en la naturaleza del problema que se intenta resolver.

Otra clasificación que se puede realizar esta basada en la capacidad de la RNA de aprender a la vez que está apta para procesar información. Este tipo de aprendizaje se denomina “on-line” o en tiempo real y el aprendizaje “off-line”. En el aprendizaje en tiempo real, una red neural entrenada para operar en un ambiente específico puede ser fácilmente reentrenable para adaptarse a los más mínimos cambios en las condiciones de operación. El caso contrario es el relacionado al aprendizaje “off-line”.

3.3.7.- Tipos de Redes Neuronales:

Una RNA está organizada en capas, las cuales agrupan una serie de neuronas que se interconectan entre sí mediante las conexiones sinápticas. En general, tenemos tres tipos de capas: una capa de entrada donde se reciben las señales del ambiente, una capa de salida donde se emiten las señales al ambiente; y un conjunto de capas que se encuentran intermedias a la capa de entrada y salida, conocidas como capas ocultas y que no tienen contacto directo con el ambiente [24].

Así, se pueden clasificar las RNA en 2 grupos:

a.- Redes Estáticas: son redes donde las neuronas de una capa se interconectan con las neuronas de la siguiente capa, desde la capa de entrada hasta la capa de salida. Además, el flujo de información en las intercapas se propagan en una sola dirección o hacia delante (feedforward). En la figura 3-14 se muestra un ejemplo de este tipo de arquitecturas.

b.- Las redes recurrentes son redes que contienen lazos de realimentación. En otras palabras, el esquema de conexión de este tipo de arquitectura se caracteriza por conexiones entre nodos de distintas capas, entre nodos de la misma capa y conexiones recurrentes de un nodo consigo mismo; donde las señales de las conexiones inter-capas se propagan en dirección hacia adelante (feedforward), o en forma realimentada (feedback); permitiendo que el flujo de información se propague en cualquier dirección y/o recurrencia.

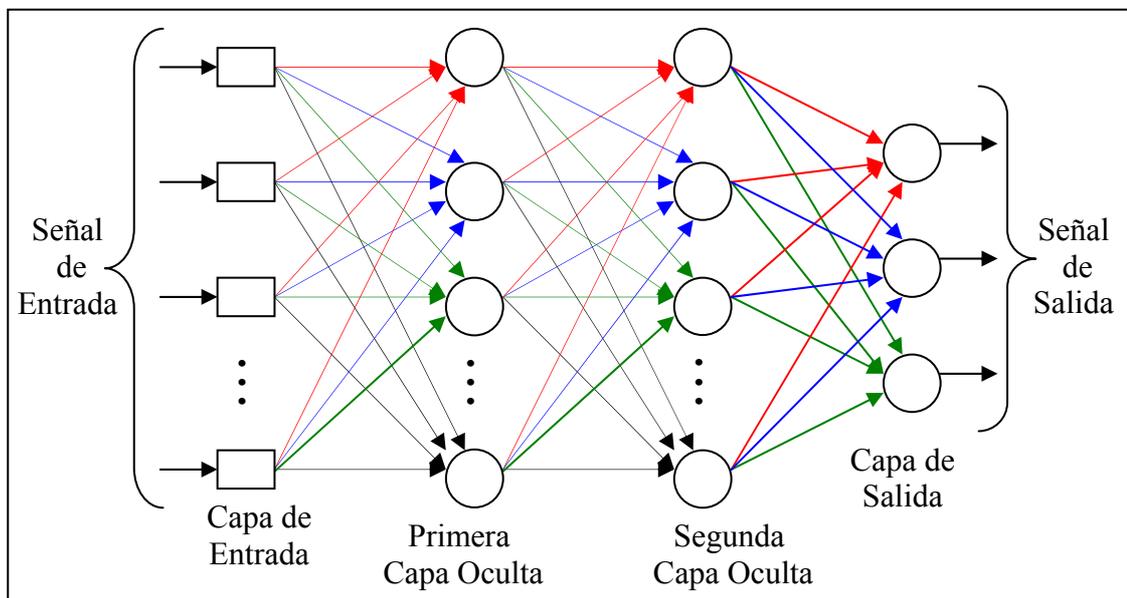


Figura 3-14. Esquema de una RNA Estática.

Podemos decir que las redes estáticas son un caso particular de las redes recurrentes y por lo tanto estas últimas representan una clase más general de arquitecturas. La figura 3-15 muestra un ejemplo de redes recurrentes.

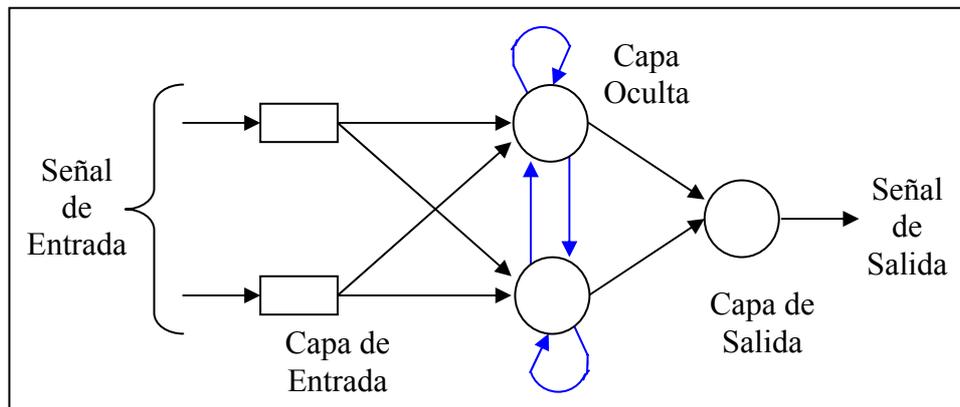


Figura 3-15. Esquema de una RNA recurrente o dinámica.

3.3.8.- Perceptrones Multicapas:

Las redes neuronales multicapas consisten de tres tipos de capas: una capa de entrada, una capa de salida y varias capas intermedias las cuales contienen unidades o neuronas ocultas (estas neuronas no tienen contacto con el exterior). Es a través de estas neuronas escondidas que el sistema puede representar las abstracciones que no se pueden codificar directamente desde el ambiente por medio de los nodos de entrada. Esto significa que se puede realizar una representación interna interesante en las unidades ocultas que no son parte de la entrada o de la salida.

Sin embargo, las entradas simplemente pasan a través de la primera capa hasta los nodos en la capa escondida sin ejecutar la función de activación y la función de salida que las neuronas normales se suponen llevan a cabo. Algunas personas consideran este tipo de red como una red de dos capas. Lo importante es notar que sólo los nodos de las capas ocultas y la capa de salida son los considerados como neuronas ordinarias, que ejecutan la función de activación y la función de salida. Se puede notar que en la estructura de la red “feedforward”, la señal de propagación se transmite solo desde la capa de entrada a la capa oculta, y desde la capa oculta a la capa de salida. No se permiten las conexiones entre los nodos de una misma capa directamente o desde la capa de entrada a la de salida. [140]



Para cada neurona “k” en la capa oculta y la neurona “l” en la capa de salida, la entrada a la red está dada por:

$$net_k = \sum_{g=1}^{Ng} W_{gk} O_g \quad k=1, \dots, Nk \quad (3.3.4)$$

$$net_j = \sum_{K=1}^{Nk} W_{Kj} O_K \quad j=1, \dots, Nj \quad (3.3.5)$$

donde: Ng: Número de neuronas en la capa de entrada.

Nk: Número de neuronas en la capa oculta.

Nj: Número de neuronas en la capa de salida.

O_i: Función de activación de la capa i.

j: Sub índice referido a las neuronas de la capa de salida.

k: Sub índice referido a las neuronas de la capa de oculta.

g: Sub índice referido a las neuronas de la capa de entrada.

La salida de las neuronas están dadas por la entrada a la neurona pasada a través de la función de activación respectiva.

$$O_g = net_g \quad (3.3.6)$$

$$O_K = \frac{1}{1 + e^{-(net_K + b_K)}} = f_K (net_K + b_K) \quad (3.3.7)$$

$$O_j = \frac{1}{1 + e^{-(net_j + b_j)}} = f_j (net_j + b_j) \quad (3.3.8)$$

donde net_g es la señal desde las fuentes externas al nodo g en la capa de entrada.[140]



Los perceptrones multicapas han sido aplicados en un rango de tareas que van más allá de simples decisiones y reconocimiento de patrones. Por ejemplo, se puede entrenar una red para formar el tiempo pasado de los verbos en inglés, leer textos y manuscritos. Es el instrumento predilecto usado para problemas de predicción de una serie de datos en el tiempo; como lo es el caso de la medición de la demanda de electricidad. Además son capaces de predecir cambios en el valor de los instrumentos y mercados financieros.

Un perceptrón multicapas posee tres características distintivas:

1.- El modelo de una neurona incluye una función de activación no lineal. Esta función debe ser continua, acotada y diferenciable; de forma que el ajuste de los pesos o entrenamiento se pueda realizar utilizando mecanismos de descenso de gradiente. Una función comúnmente utilizada y que satisface estos requerimientos es la función sigmoideal.[139]

2.- La red contiene uno o más capas de neuronas ocultas. Estas neuronas ocultas capacitan a la red para aprender tareas complejas por la extracción progresiva de aspectos más significativos de los patrones de entrada (vectores). Además, permiten que la red sea capaz de extraer altos órdenes estadísticos, es decir, en un sentido bastante general, la red adquiere una perspectiva global (a pesar de sus conexiones locales) debido al grupo extra de conexiones sinápticas y a la dimensión extra de interacciones de las neuronas. La habilidad de las neuronas intermedias en extraer altos ordenes estadísticos es particularmente importante cuando el tamaño de la capa de entrada es grande [139].

3.- La red exhibe un alto grado de conectividad, determinada por las conexiones sinápticas (entre neuronas) de la red. Un cambio en la conectividad de la red requiere un cambio en las conexiones sinápticas o en los pesos.

Es a través de la combinación de estas características, junto con la habilidad de aprender por medio del entrenamiento, que el perceptron multicapa posee una alta



capacidad computacional. Sin embargo, son estas mismas características las responsables de complicar el análisis de esta topología para entender completamente el comportamiento de la red y así obtener el máximo provecho. La presencia de una forma no lineal distribuida en la alta conectividad de la red hace el análisis teórico de un perceptron multicapa difícil de emprender. Además, el proceso de aprendizaje se hace aún más difícil porque la búsqueda (del aprendizaje) debe ser conducida en un espacio más grande de funciones posibles, y se debe realizar una selección entre las representaciones alternativas del patrón de entrada. [139]

3.3.9.- Algoritmo de Retropropagación o “Backpropagation”.

Los perceptrones multicapas deben ser entrenados con datos históricos para encontrar los valores apropiados para los pesos (W), y para el número de neuronas requeridas en la capa escondida. El algoritmo de aprendizaje empleado con mayor frecuencia en el entrenamiento de las redes neurales es el error “backpropagation” (retropropagación), también llamado simplemente “backpropagation” (BP). En BP, el aprendizaje se realiza mediante el ajuste de los pesos. La salida producida por la RNA es comparada varias veces con la respuesta correcta. La señal de error es propagada hacia atrás a través de la red, en dirección contraria a las conexiones sinápticas, de allí el nombre “backpropagation”. Cada vez que ocurre esto, los valores de los pesos son ligeramente ajustados en dirección a la respuesta correcta en la capa de salida, de acuerdo al algoritmo de gradiente descendente.

La técnica de “backpropagation” parte del manejo de la señal de error (diferencia entre la señal de salida y la respuesta objetivo). Luego que la señal de entrada se presenta, se calcula la respuesta de la RNA y se minimiza el valor del error, definido en forma de una función de energía, tal como lo muestra la ecuación (3.3.9):

$$E = \frac{1}{2} \sum_K (t_k - O_k)^2 \quad (3.3.9)$$



donde:

t_k es respuesta deseada del ejemplo k .

O_k es respuesta obtenida por la red en el ejemplo k .

La idea general detrás de la regla del gradiente descendiente es hacer un cambio en los pesos proporcional al opuesto de la derivada del error. Así, se calcula la derivada de la función error con respecto a cualquier peso de la red y se cambia el peso de acuerdo a lo siguiente:

$$\Delta w_{ij} = -\varepsilon \frac{dE}{dw_{ij}} \quad (3.3.10)$$

$$W_{ij}(n+1) = W_{ij}(n) + \Delta W_{ij} \quad (3.3.11)$$

donde ε : constante de proporcionalidad

E : función de error.

La constante de proporcionalidad, a la cual también se suele referir como tasa de aprendizaje, es un factor importante para este método. En los procedimientos del gradiente descendente se usa una tasa de aprendizaje pequeña. Los valores grandes pueden proporcionar una rápida convergencia, pero cuando los valores son demasiado grandes podrían existir problemas de oscilaciones en la convergencia.

Con la escogencia apropiada de una función no lineal se puede realizar la diferenciación y obtener la siguiente expresión.

$$\Delta W_{ij} = -\varepsilon \delta_{pi} f_{pi} \quad (3.3.12)$$

Así, los pesos deben ser cambiados por una cantidad proporcional al término “ δ ” (variación del error con respecto a la entrada de la neurona i), y el valor de la función de activación f .



Para determinar el valor de delta se usa un proceso recursivo que comienza con las neuronas de salida. Si una neurona forma parte de la capa de salida, su valor de δ está dado por la siguiente ecuación:

$$\delta_{pj} = (t_{pj} - a_{pj}) f'_{pj} (net_{pj}) \quad (3.3.13)$$

donde t_{pj} : valor deseado de la señal de activación.

Net_j: función de entrada a una neurona, definida como $net_{pj} = \sum w_{ij} f_{pk} + bias_i$

$f'(net_j)$: derivada de la función de activación con respecto a un cambio en la entrada de la red.

La gran virtud de la regla de BP viene de la asignación de las deltas a las unidades escondidas, que no reciben una realimentación directa de los patrones de entrenamiento en el ambiente. Estas deltas influyen en la modificación de los pesos que conectan las principales neuronas de la capa escondida. Para las neuronas de las capas ocultas donde no hay un objetivo o salida predeterminada, el valor de delta se obtiene de forma recursiva, en función de los términos deltas de las neuronas a las cuales están conectadas directamente, y el peso de estas conexiones.

Esto se representa de la siguiente manera:

$$\delta_{pk} = f'_{pk} (net_{pk}) \sum_k \delta_{pj} w_{kj} \quad (3.3.14)$$

La regla de aprendizaje de BP requiere que la derivada de la función de activación exista, que sea continua y no lineal. La función de activación que se suele usar para estos estudios de predicción y que se usará en este trabajo es:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.3.15)$$



Para aplicar la regla de aprendizaje, se debe conocer la derivada de esta función con respecto a todas sus entradas, y en este caso está dada por:

$$\frac{df(x)}{dx} = f(x)(1 - f(x)) \quad (3.3.16)$$

Así, la señal de error δ_{pj} para una neurona perteneciente a la capa de salida esta dada por (3.3.17) y para una neurona de una capa oculta esta dada por (3.3.18).

$$\delta_{pj} = (t_{pj} - f_{pj})f_{pj}(1 - f_{pj}) \quad (3.3.17)$$

$$\delta_{pk} = f_{pk}(1 - f_{pk}) \sum_k \delta_{pj} W_{kj} \quad (3.3.18)$$

Para mejorar la convergencia del proceso de aprendizaje, se puede agregar un término, denominado momentum (α), a la regla de BP. Esto puede ser realizado de la forma como se muestra en (3.3.19):

$$\Delta W_{ij}(n+1) = \varepsilon(\delta_{pi} f_{pj}) + \alpha \Delta W_{ij}(n) \quad (3.3.19)$$

donde α es una constante que determina el efecto de los cambios pasados de los pesos en la dirección correcta hacia la convergencia y el cual usualmente se toma como 0.9.

El desarrollo del algoritmo de “backpropagation” representa un acontecimiento decisivo en redes neurales, ya que provee un método eficiente computacionalmente para el entrenamiento de perceptrones multicapa. Aunque no se puede declarar que el algoritmo “back-propagation” provee una solución óptima para todos los problemas que posean solución, dicho algoritmo de aprendizaje ha sido ampliamente probado en PM, demostrando su superioridad sobre otros métodos. En el Apéndice A se presenta una deducción detallada de dicho algoritmo de entrenamiento. [139]



3.3.10.- Redes Neuronales de Base Radial:

Diversos trabajos como los mencionados en la revisión bibliográfica, han demostrado una marcada tendencia al uso de las redes de base radial, en vez de los del tipo retro-propagación y es que diversos estudios 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: $\mathbf{x}_i \in \mathbb{R}^p \quad i = 1, 2, \dots, n$
- Salidas: $d_i \in \mathbb{R}$

La red con esta función, implementa un mapeo del tipo

$$F(\mathbf{x}) : \mathbb{R}^p \longrightarrow \mathbb{R} \tag{3.3.20}$$

Donde:

$$F(\mathbf{x}) = \sum_{i=1}^M w_i G_i(\|\mathbf{x} - \mathbf{c}_i\|) \tag{3.3.21}$$

Donde $\mathbf{x} \in \mathbb{R}^p$, $\|\cdot\|$ es la norma y

$\mathbf{c}_i \in \mathbb{R}^p$, son los centros de las M funciones bases G_i (funciones exponenciales gaussianas de ancho σ_i)

$$G_i(\|\mathbf{x} - \mathbf{c}_i\|) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right) \tag{3.3.22}$$

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

$$C(\mathbf{w}) = \|\mathbf{d} - \mathbf{G}\mathbf{w}\|^2 + \lambda \mathbf{w}^T \mathbf{G}_0 \mathbf{w} \quad (3.3.23)$$

Donde $\mathbf{w} \in \mathbb{R}^{M \times 1}$, $\mathbf{d} \in \mathbb{R}^{N \times 1}$, $\mathbf{G} \in \mathbb{R}^{N \times M}$ y $\mathbf{G}_0 \in \mathbb{R}^{M \times M}$

$$\mathbf{w} = [w_1 \ w_2 \ \dots \ w_M]^T \quad (3.3.24)$$

$$\mathbf{d} = [d_1 \ d_2 \ \dots \ d_N]^T \quad (3.3.25)$$

$$\mathbf{G} = \begin{bmatrix} G(\|\mathbf{x}_1 - \mathbf{c}_1\|) & \dots & G(\|\mathbf{x}_1 - \mathbf{c}_M\|) \\ G(\|\mathbf{x}_2 - \mathbf{c}_1\|) & \dots & G(\|\mathbf{x}_2 - \mathbf{c}_M\|) \\ \vdots & \ddots & \vdots \\ G(\|\mathbf{x}_N - \mathbf{c}_1\|) & \dots & G(\|\mathbf{x}_N - \mathbf{c}_M\|) \end{bmatrix} \quad (3.3.26)$$

$$\mathbf{G}_0 = \begin{bmatrix} G(\|\mathbf{c}_1 - \mathbf{c}_1\|) & \dots & G(\|\mathbf{c}_1 - \mathbf{c}_M\|) \\ G(\|\mathbf{c}_2 - \mathbf{c}_1\|) & \dots & G(\|\mathbf{c}_2 - \mathbf{c}_M\|) \\ \vdots & \ddots & \vdots \\ G(\|\mathbf{c}_M - \mathbf{c}_1\|) & \dots & G(\|\mathbf{c}_M - \mathbf{c}_M\|) \end{bmatrix}. \quad (3.3.27)$$

L se denomina el parámetro de regularización y establece el grado de generalización de la red para los parámetros estudiados.

La minimización de la ecuación (3.3.23), con respecto a los pesos \mathbf{w} , lleva a la solución:

$$\mathbf{w} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{G}_0)^{-1} \mathbf{G}^T \mathbf{d} \quad (3.3.28)$$

Un esquema de este tipo de redes se muestra en la Fig. 3-16, 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 $F_j(x)$.

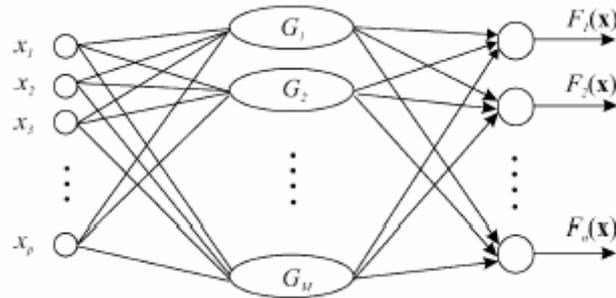


Fig. 3-16. Esquema de una red neuronal con arquitectura de base radial. “p” entradas, “n” salidas y M funciones G_i .

3.3.11.- Redes Neuronales del Tipo Probabilístico:

La red neuronal del tipo probabilística es ideal para problemas de clasificación [139] y cae dentro del grupo de técnicas no paramétricas en el argot de inteligencia artificial.

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 para 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 arquitectura más simple de este sistema, se muestra en la Fig. 3-17 [141].

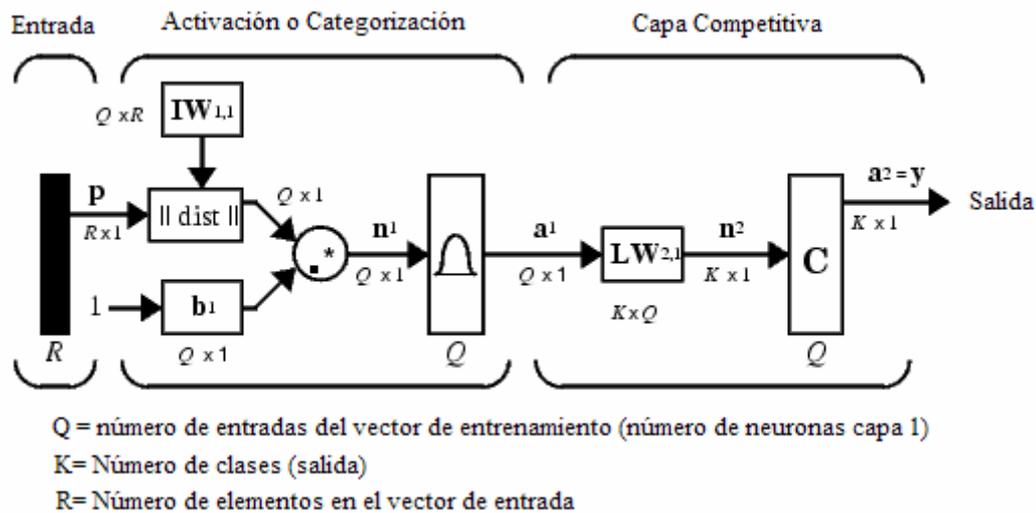


Fig. 3-17. Arquitectura base de una red neuronal del tipo probabilística.

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 PD para cada vector de entrada, comparándolo con los vectores de entrenamiento para las clases o categorías de salida pre-especificadas.

$$p_n(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{V_n} \varphi \left(\frac{\mathbf{x} - \mathbf{x}_i}{h_n} \right) \quad (3.3.29)$$

Donde:

“n”: es el tamaño del vector de entrenamiento.

$$V_n = 1/\sqrt{n} \quad (3.3.30)$$

H_n: es un factor de agrupamiento.

Y la función φ , viene representada, por:

$$\varphi(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2} \quad (3.3.31)$$

En la Figura 3-18, se observa el efecto de la cantidad de patrones de entrenamiento y del factor h_n , en cuanto a la clasificación del algoritmo planteado para la red.

Así, mientras h_n sea menor, más se deben acercar los valores a identificar con algún patrón de entrenamiento para que pueda ser clasificado como el más probable y con h_n intermedios, se puede tener un buen rango para generalizar el comportamiento de la red en casos con alta dispersión en los datos.

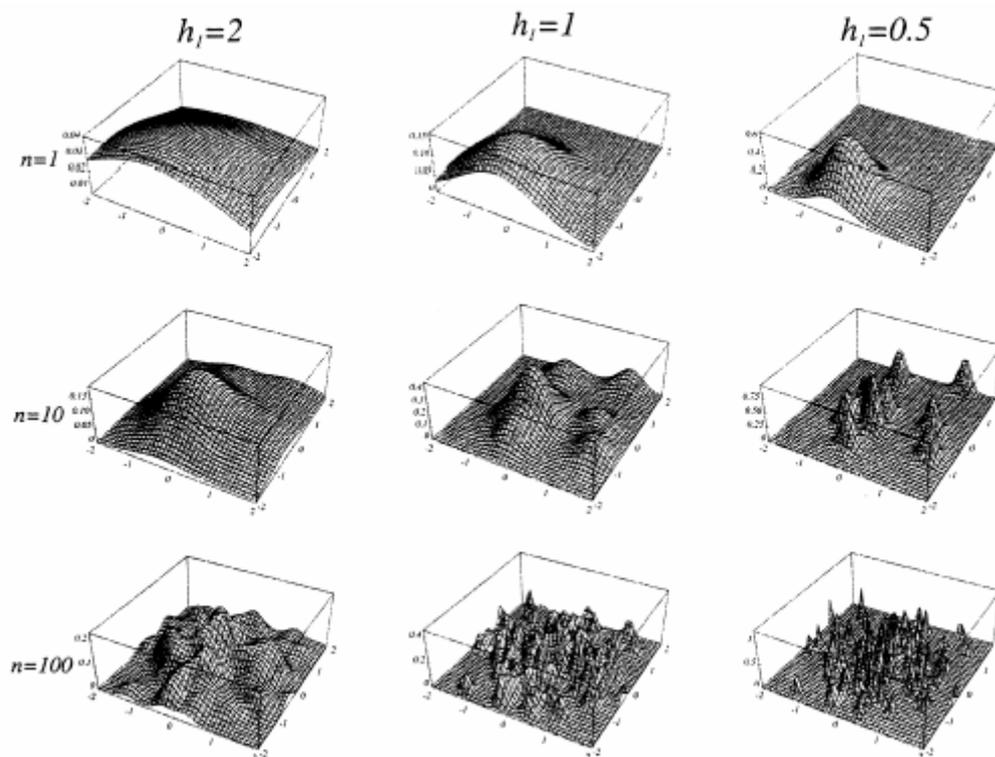


Fig. 3-18. Comportamiento de la densidad bivarita de Parzen como función de activación en una red neuronal probabilística.



4.- PLANTEAMIENTO DEL ALGORITMO

4.1.- Introducción:

El presente capítulo desarrolla la metodología específica a utilizar en cada una de las tareas previamente descritas de detección, clasificación, discriminación direccional y localización de una falta.

Para ello, se inicia con un desarrollo previo de las herramientas que van a ser utilizadas, como la transformación modal o el “Modulus Máxima” de una transformada Wavelet.

Posteriormente se describirá el algoritmo planteado para cada tarea de forma independiente e incluyendo en algunos casos, propuestas diferentes pero igual de válidas y que permitan tener una visión amplia en el ataque del problema concreto.

4.2.- Herramientas Previas

4.2.1.- Línea de Transporte y Onda Viajera:

Para el mejor entendimiento del fenómeno ligado a la generación de ondas viajeras tras la ocurrencia de una falta en un sistema eléctrico de potencia y en particular en una línea de transporte de energía, se plantea la representación de la línea a través de las ecuaciones del telegrafista. En la Fig. 4-1, se muestra una sección infinitesimal de la línea de transmisión.

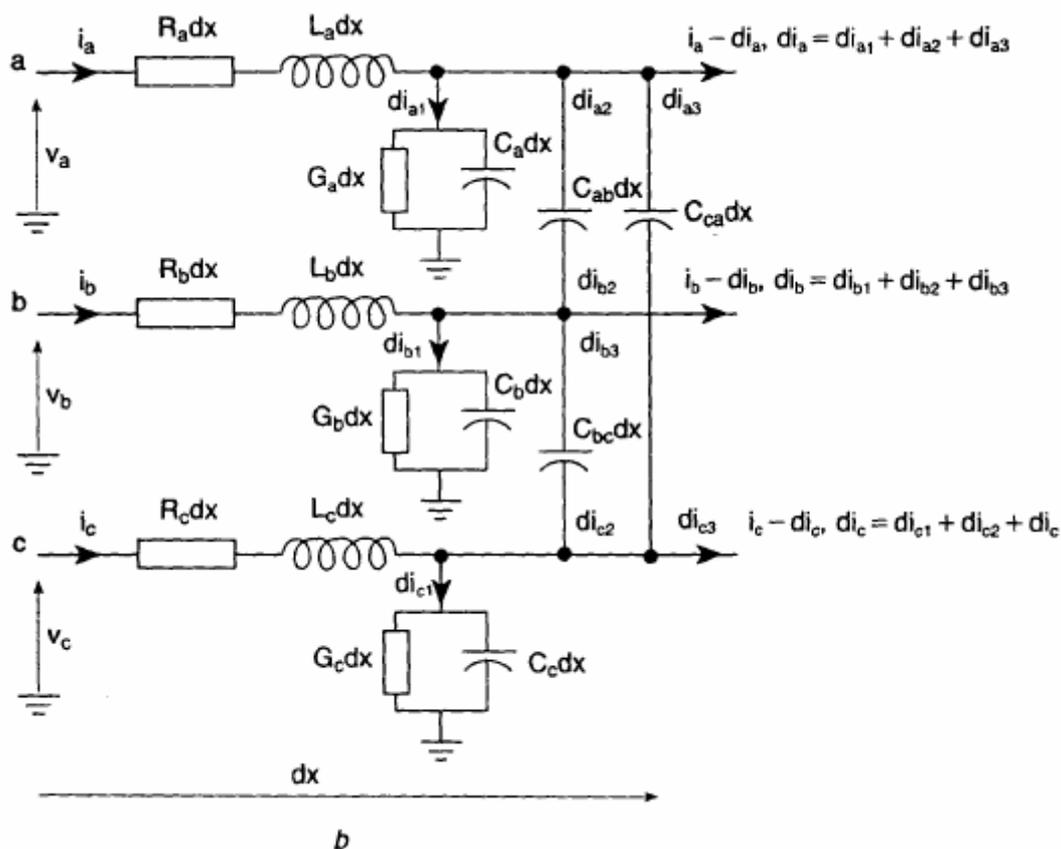


Fig. 4-1. Representación de un segmento de la línea de transmisión (parámetros distribuidos) [2].

Donde R_ϕ , L_ϕ , G_ϕ y C_ϕ , son los parámetros de la línea por unidad de longitud, con $\phi = a, b, c$.



Así, para la fase a:

$$dv_a = \frac{\partial v_a}{\partial x} dx = \left(R_a dx + L_a dx \frac{\partial}{\partial t} \right) i_a + L_{ab} dx \frac{\partial i_b}{\partial t} + L_{ca} dx \frac{\partial i_c}{\partial t} \quad (4.2.1)$$

$$di_a = \frac{\partial i_a}{\partial x} dx = \left(G_a dx + C_a dx \frac{\partial}{\partial t} \right) v_a + C_{ab} dx \frac{\partial v_{ab}}{\partial t} + C_{ca} dx \frac{\partial v_{ac}}{\partial t} \quad (4.2.2)$$

Las mismas ecuaciones anteriores, pueden ser escritas para las fases b y c.

Si para resumir se plantea el sistema de forma matricial:

$$\frac{\partial \mathbf{v}}{\partial x} = \mathbf{z} \mathbf{i} \quad (4.2.3)$$

$$\frac{\partial \mathbf{i}}{\partial x} = \mathbf{y} \mathbf{v} \quad (4.2.4)$$

Donde:

$$\mathbf{v} = \begin{bmatrix} v_a \\ v_b \\ v_c \end{bmatrix} \quad (4.2.5)$$

$$\mathbf{i} = \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (4.2.6)$$

$$\mathbf{z} = \begin{bmatrix} R_a + L_a \frac{\partial}{\partial t} & L_{ab} \frac{\partial}{\partial t} & L_{ca} \frac{\partial}{\partial t} \\ L_{ab} \frac{\partial}{\partial t} & R_b + L_b \frac{\partial}{\partial t} & L_{bc} \frac{\partial}{\partial t} \\ L_{ca} \frac{\partial}{\partial t} & L_{bc} \frac{\partial}{\partial t} & R_c + L_c \frac{\partial}{\partial t} \end{bmatrix} \quad (4.2.7)$$



$$y = \begin{bmatrix} G_a + C_{aa} \frac{\partial}{\partial t} & -C_{ab} \frac{\partial}{\partial t} & -C_{ca} \frac{\partial}{\partial t} \\ -C_{ab} \frac{\partial}{\partial t} & G_b + C_{bb} \frac{\partial}{\partial t} & -C_{bc} \frac{\partial}{\partial t} \\ -C_{ca} \frac{\partial}{\partial t} & -C_{bc} \frac{\partial}{\partial t} & G_c + C_{cc} \frac{\partial}{\partial t} \end{bmatrix} \quad (4.2.8)$$

Con:

$$C_{aa} = C_a + C_{ab} + C_{ca} \quad (4.2.9)$$

$$C_{bb} = C_b + C_{ab} + C_{bc} \quad (4.2.10)$$

$$C_{cc} = C_c + C_{bc} + C_{ca} \quad (4.2.11)$$

Si se sustituye el operador $\frac{\partial}{\partial t}$, por su transformada en el dominio de la frecuencia, y trabajando con el sistema de las ecuaciones (4.2.3) y (4.2.4), se llega al siguiente sistema de ecuaciones diferenciales.

$$\frac{\partial^2 v}{\partial x^2} = \gamma^2 v \quad (4.2.12)$$

$$\frac{\partial^2 i}{\partial x^2} = \gamma^2 i \quad (4.2.13)$$

Donde:

$$\gamma^2 = (R + Ls)(G + Cs) \quad (4.2.14)$$

Y se puede demostrar que se obtiene la siguiente solución, para las tensiones y corrientes en el dominio de la frecuencia:

$$v(x) = K1 \cdot e^{-\gamma x} + K2 \cdot e^{\gamma x} \quad (4.2.15)$$



$$i(x) = \frac{(K1 \cdot e^{-\gamma x} - K2 \cdot e^{\gamma x})}{Z_0} \quad (4.2.16)$$

Donde:

$$Z_0 = \sqrt{\frac{(R + Ls)}{(G + Cs)}} \quad (4.2.17)$$

Pero, el interés primordial es obtener dicha solución en el dominio del tiempo y no de la frecuencia, por lo que queda:

$$v(x,t) = e^{-\alpha x} F\left(t - \frac{x}{v}\right) + e^{\alpha x} B\left(t + \frac{x}{v}\right) \quad (4.2.18)$$

$$i(x,t) = \frac{(e^{-\alpha x} F\left(t - \frac{x}{v}\right) - e^{\alpha x} B\left(t + \frac{x}{v}\right))}{Z_0} \quad (4.2.19)$$

Donde:

$$\alpha = R/Z_0 \quad (4.2.20)$$

Reduciendo, se puede indicar que las expresiones tanto de tensión como de corriente poseen dos componentes: la componente progresiva (v^+ o i^+) y una componente regresiva (v^- ó i^-), por lo que la solución podría ser rescrita, como sigue:

$$v = v^+ + v^- \quad (4.2.21)$$

$$i = i^+ + i^- \quad (4.2.22)$$

Estas componentes pueden ser representadas gráficamente como se indica en la Fig. 4-2, tanto para tensiones como para corrientes.

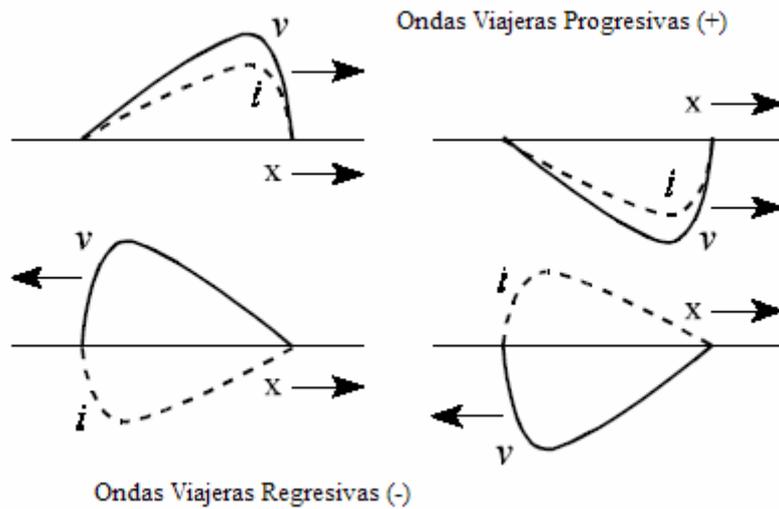


Fig. 4-2. Representación de las componentes progresivas y regresivas de una onda.

Estas componentes progresivas y regresivas (para la tensión), pueden ser expresadas para una localización x definida y para un instante de tiempo, como:

$$F_v = v + Z_0 i = v^+ \quad (4.2.23)$$

$$B_v = v - Z_0 i = v^- \quad (4.2.24)$$

Esta información (parámetros F y B), son muy importantes para establecer la direccionalidad primordial de ciertas ondas medidas en un nodo de una red eléctrica, como en el caso de una falta en el sistema.

Sin embargo, trabajar con estas expresiones en el dominio de las fases, resulta complicado debido a la posible no simetría de los parámetros. Para ello, lo que de forma tradicional se lleva a cabo es plantear la solución en el dominio modal, transformando las cantidades de fase en cantidades modales, mediante una matriz de cambio.



4.2.2.- Transformación Modal:

Para poder trabajar de una forma desacoplada sistemas multifásicos desbalanceados y simplificar enormemente los cálculos asociados, se hace necesario plantear una transformación que convierta el sistema trifásico convencional acoplado en un grupo de sistemas desacoplados. Para ello, Fortescue planteó en 1914, la transformación de las componentes simétricas.

Sin embargo, para el trabajo de análisis de ondas en el dominio del tiempo y no de la frecuencia, se plantea la transformación modal por estar representada en matrices reales.

Para el objetivo del presente trabajo no es necesaria la transformación aplicada a la red de forma directa, sino a las variables eléctricas registradas en los nodos (corrientes y tensiones), por lo que se plantea trabajar no con las transformaciones específicamente calculadas por medio de la teoría matricial de autovectores y autovalores y que permiten desacoplar los parámetros de una línea particular, sino simplemente el desacople de tensiones y corriente.

La transformación clásica de componentes simétricas, tiene la siguiente forma:

$$\begin{bmatrix} v_1 \\ v_2 \\ v_0 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & e^{j\frac{2\pi}{3}} & e^{-j\frac{2\pi}{3}} \\ 1 & e^{-j\frac{2\pi}{3}} & e^{j\frac{2\pi}{3}} \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} va \\ vb \\ vc \end{bmatrix} \quad (4.2.25)$$

$$v_s = [T]^{-1} v_\phi \quad (4.2.26)$$

La complicación que tiene esta matriz T para aplicaciones en tiempo real, radica en su naturaleza compleja, pues implica la evaluación equivalente de señales en diferentes instantes de tiempo. Este problema ha sido relativamente solucionado para



aplicaciones donde es posible trabajar con datos en memoria, convirtiendo los exponenciales complejos en muestreos desfasados en tiempo, tal como se indica a continuación:

Si llamamos $\tau = 2\pi$, entonces queda

$$3 \cdot v_1 = va + vb \cdot e^{-j\frac{2\tau}{3}} + vc \cdot e^{-j\frac{\tau}{3}} \quad (4.2.27)$$

$$3 \cdot v_2 = va + vb \cdot e^{-j\frac{\tau}{3}} + vc \cdot e^{-j\frac{2\tau}{3}} \quad (4.2.28)$$

$$3 \cdot v_0 = va + vb + vc \quad (4.2.29)$$

Si se utiliza como intervalo de integración $\Delta t = \tau/3$, las expresiones anteriores quedarían representadas en el dominio del tiempo, de la siguiente manera:

$$3 \cdot v_1(t) = va(t) + vb(t - \frac{2\tau}{3}) + vc(t - \frac{\tau}{3}) \quad (4.2.30)$$

$$3 \cdot v_2(t) = va(t) + vb(t - \frac{\tau}{3}) + vc(t - \frac{2\tau}{3}) \quad (4.2.31)$$

$$3 \cdot v_0(t) = va(t) + vb(t) + vc(t) \quad (4.2.32)$$

Dependiendo de la tasa de muestreo de la señal, esto puede llevarse a un equivalente de cantidad de muestras guardadas en memoria. Por ejemplo, si se utiliza un muestreo de 12 Muestras/ciclo, se tendría un $\omega t = 30^\circ$, lo que implicaría:

$$3 \cdot v_1(t) = va(t) + vb(t - 8) + vc(t - 4) \quad (4.2.33)$$

Lo anterior indicaría que es necesario guardar hasta ocho muestras de cada señal, lo cual es cuantioso en carga, especialmente para aplicaciones en tiempo real. Así que lo



que se propone es un cambio en el planteamiento, dada la siguiente relación compleja.

Si se sabe que,

$$e^{\pm j\frac{2\pi}{3}} = \sqrt{3} \cdot e^{\pm j\frac{\pi}{6}} - 2 \quad (4.2.34)$$

$$e^{\pm j\frac{4\pi}{3}} = -\sqrt{3} \cdot e^{\pm j\frac{\pi}{6}} + 1 \quad (4.2.35)$$

Con esta relación puede llegarse en los casos complicados de v_1 y v_2 , a

$$3 \cdot v_1 = va - \sqrt{3} \cdot vb \cdot e^{-j\frac{\pi}{6}} + vb + \sqrt{3} \cdot vc \cdot e^{-j\frac{\pi}{6}} - 2 \cdot vc \quad (4.2.36)$$

$$3 \cdot v_2 = va - \sqrt{3} \cdot vb \cdot e^{-j\frac{\pi}{6}} - 2 \cdot vb - \sqrt{3} \cdot vc \cdot e^{-j\frac{\pi}{6}} + vc \quad (4.2.37)$$

Por lo que en tiempo y con la tasa de muestreo indicada anteriormente, se tendría

$$3 \cdot v_1(t) = va(t) - 2 \cdot vc(t) + vb(t) + \sqrt{3}(vc(t-1) - vb(t-1)) \quad (4.2.38)$$

$$3 \cdot v_2(t) = va(t) + vc(t) - 2 \cdot vb(t) + \sqrt{3}(vb(t-1) - vc(t-1)) \quad (4.2.39)$$

En este caso el problema estaría resuelto pues implicaría trabajar solo con la muestra anterior. Esto es válido para algoritmos basados en muestreos bajos (pocos kHz), pero se vuelve engorroso para aplicaciones basadas en transitorios, donde las frecuencia de muestreo rondan el MHz, así por ejemplo para una tasa de muestreo de 120 Muestras por ciclo, la solución anterior implicaría el almacenamiento de las señales en $(t-10)$, lo cual lo volvería poco atractivo, a pesar de la información que podría arrojar esta transformada al compararla con otras.

Ese problema se generaliza y complica para otras transformaciones complejas, por lo que se busca aplicar aquellas conocidas que son reales, como por ejemplo las mencionadas a continuación (Clark, Wedephol o Karrenbauer) que son las más clásicas utilizadas para el desacople del dominio de fases al dominio modal, en aplicaciones de estudios transitorios (onda viajera).



Si bien estas matrices no tienen las mismas propiedades que las de componentes simétricas, permiten desacoplar en dos modos a las señales de tensión o corriente (modo aéreo y modo tierra, en caso de líneas de transporte), que permiten resolver de forma sencilla los fenómenos relacionados con ondas viajeras.

Estas matrices, son:

a.- Transformación de Clark:

$$[T_{Clark}] = \begin{bmatrix} 1 & 1 & 0 \\ 1 & -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ 1 & -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \quad (4.2.40)$$

b.- Transformación de Wedepohl

$$[T_w] = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & -2 \\ 1 & -1 & 1 \end{bmatrix} \quad (4.2.41)$$

c.- Transformación de Karrenbauer

$$[T_k] = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ 1 & 1 & -2 \end{bmatrix} \quad (4.2.42)$$



Partiendo del hecho que:

$$V_f = [T] V_m \quad (4.2.43)$$

Donde:

$$v_f = \begin{bmatrix} va \\ vb \\ vc \end{bmatrix} \quad y \quad v_m = \begin{bmatrix} v_0 \\ v_\alpha \\ v_\beta \end{bmatrix} \quad (4.2.44)$$

Aunque no ha sido indicado, cabe resaltar que esas matrices han sido obtenidas utilizando como referencia a la fase A.

Por otro lado, en este trabajo se ha seleccionado por la relevancia de la información suministrada para el caso de estudio de faltas, la transformación de Karrenbauer (después de variedad de ensayos realizados sobre diferentes señales analizadas).

También se debe destacar que al igual que en el estudio convencional de faltas que se realiza en régimen estacionario, referenciar adecuadamente la matriz de transformación con la fase fallada, permite reducir sensiblemente el análisis y en el caso de trabajar con aplicaciones sobre señales en el dominio del tiempo, obtener mejor calidad de la información, especialmente en lo que respecta a los modos aéreos que es donde hay cambios.



Así se plantea una matriz no cuadrada de transformación que maneje toda la información necesaria, tal como se indica a continuación:

$$\begin{bmatrix} va \\ vb \\ vc \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 & -2 & -2 & 1 \\ 1 & -2 & 1 & 1 & 1 & 1 & -2 \\ 1 & 1 & -2 & -2 & 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} v_0 \\ v_{\alpha[ta]} \\ v_{\beta[ta]} \\ v_{\alpha[tb]} \\ v_{\beta[tb]} \\ v_{\alpha[tc]} \\ v_{\beta[tc]} \end{bmatrix} \quad (4.2.45)$$

Donde ta, tb y tc, son los términos modales referenciados a las fases a, b y c, respectivamente.

Lo interesante de esta matriz, es que su inversa es muy fácil de utilizar en aplicaciones “on-line” en tiempo real, pues la obtención de las cantidades modales referidas a cualquier fase, corresponde únicamente a sumas y restas directas.

$$\begin{bmatrix} v_0 \\ v_{\alpha[ta]} \\ v_{\beta[ta]} \\ v_{\alpha[tb]} \\ v_{\beta[tb]} \\ v_{\alpha[tc]} \\ v_{\beta[tc]} \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \\ 0 & 1 & -1 \\ -1 & 1 & 0 \\ -1 & 0 & 1 \\ 0 & -1 & 1 \end{bmatrix} \begin{bmatrix} va \\ vb \\ vc \end{bmatrix} \quad (4.2.46)$$

De esa forma, pueden ser resueltas las ecuaciones de onda viajera, para cada modo, reduciéndose significativamente en complejidad al eliminar los acoples

existentes en el dominio de las fases. Así cada función de tensión o corriente, puede ser planteada:

$$V_{\alpha,\beta,0} = V_{\alpha,\beta,0}^+ + V_{\alpha,\beta,0}^- \quad (4.2.47)$$

$$i_{\alpha,\beta,0} = i_{\alpha,\beta,0}^+ + i_{\alpha,\beta,0}^- \quad (4.2.48)$$

Donde + y -, son los términos progresivos y regresivos ya definidos en el punto anterior.

Por último se coloca a modo de ejemplo para tener en cuenta lo que significa el desacople en modos, la aplicación de la transformación modal a una señal de tensión para un caso particular de falta en la Fase A.

Dado que la falta es en la fase A, se va a utilizar únicamente la información modal correspondiente a las referencias matriciales respecto a esta fase.

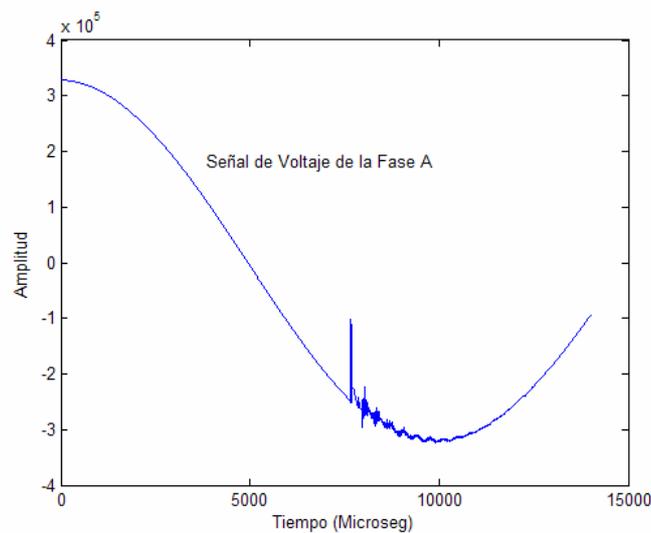


Fig. 4-3. Forma de onda de la tensión en la Fase A, ante un Cortocircuito A-G.

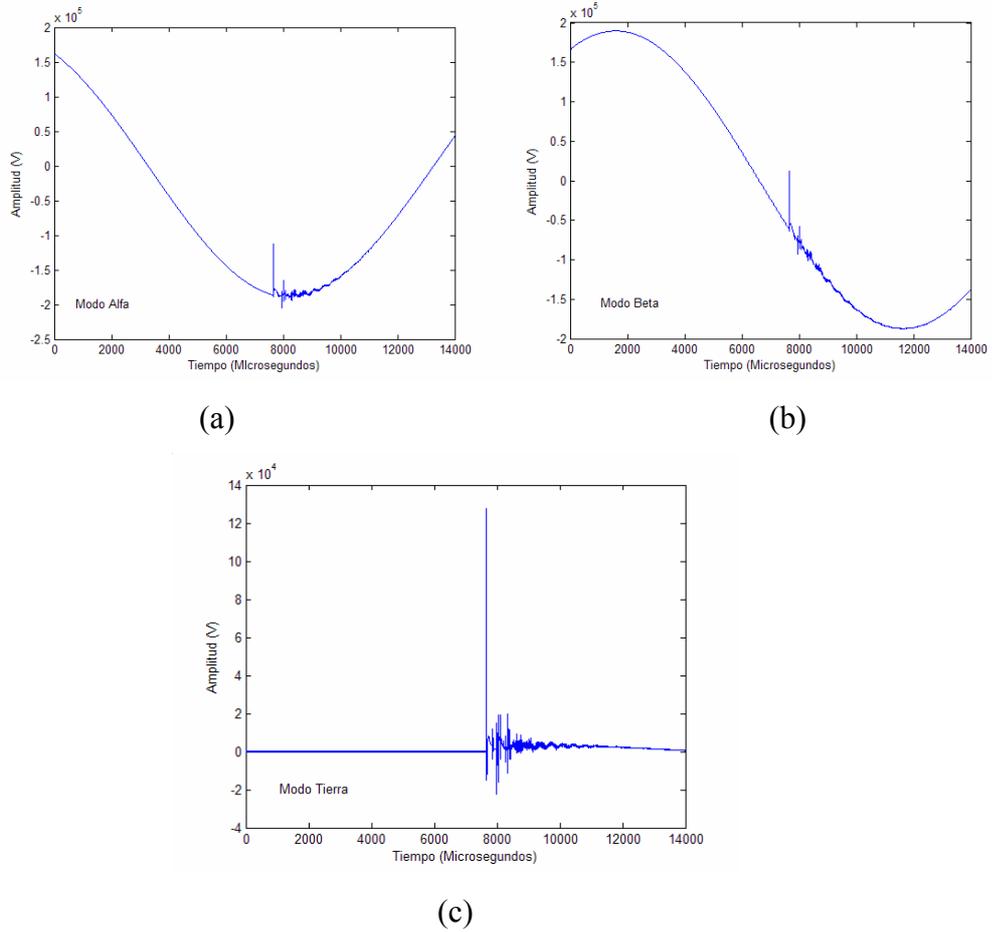


Fig. 4-4. Descomposición modal (α , β , 0) de la señal de tensión de la fase A. (a) Modo α , (b) modo β y (c) modo tierra

4.2.3.- Aplicación del concepto de “Modulus Maxima” a la transformada Wavelet:

Siguiendo con la descripción de las herramientas útiles para el análisis y desarrollo del algoritmo de localización planteado, se va a continuación a describir el “Modulus Maxima” de una señal transformada por wavelets, para el mejor aprovechamiento de la información suministrada.

En el capítulo anterior, se establecieron de forma simplificada las bases de la transformada wavelets en todas sus modalidades (continua, discreta, etc). El problema es que por la naturaleza de la función madre que se utiliza en la transformación, la señal transformada posee un comportamiento oscilatorio en los puntos de discontinuidad que son precisamente los de interés en este estudio.

Para simplificar la cantidad de información suministrada por dicha transformación, lo que plantea el “Modulus Maxima”, es obtener para cada discontinuidad, simplemente el mayor valor de la transformada en ese punto, despreciando el resto de la información.

La mejor forma de justificarlo antes de indicar el procedimiento matemático para su obtención, es indicando su utilidad a través de un ejemplo con una forma de onda de la tensión en la fase A, para una falla monofásica en un sistema típico de transmisión (Fig. 4-5).

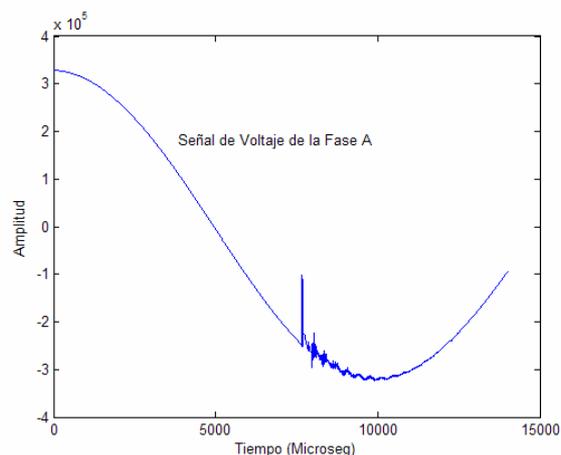


Fig. 4-5. Forma de onda de la tensión en la Fase A.

La transformada Wavelets de esa onda, se indica en la próxima Figura, variando el tipo de transformada utilizada (continua compleja: información combinada y discreta db4- d1).

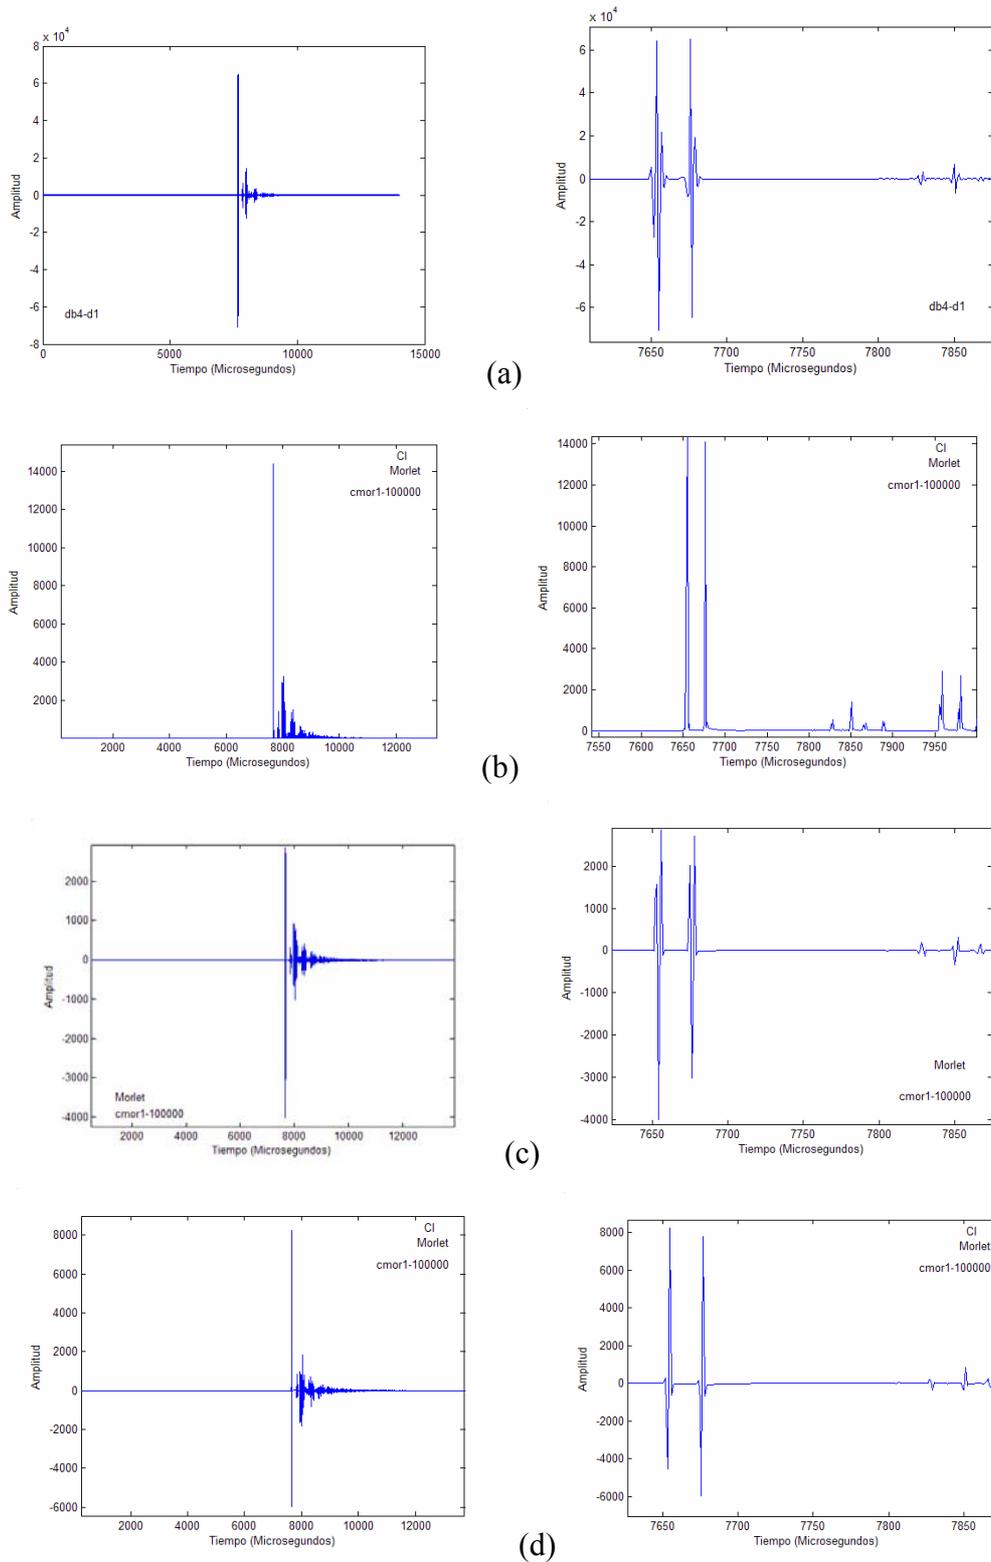


Fig. 4-6. Transformada Wavelet de la tensión. (a) DWT con db4 – d1, (b) CWT compleja Morlet ($F_a=1$, $F_b=10000$), Información combinada (CI), (c) Parte real de la CWT Compleja y (d) Parte imaginaria de la CWT compleja.

Entrando en detalle, se puede apreciar al comparar la onda de tensión con la parte real de la transformada continua compleja de Morlet, las oscilaciones presentes en el punto de discontinuidad.

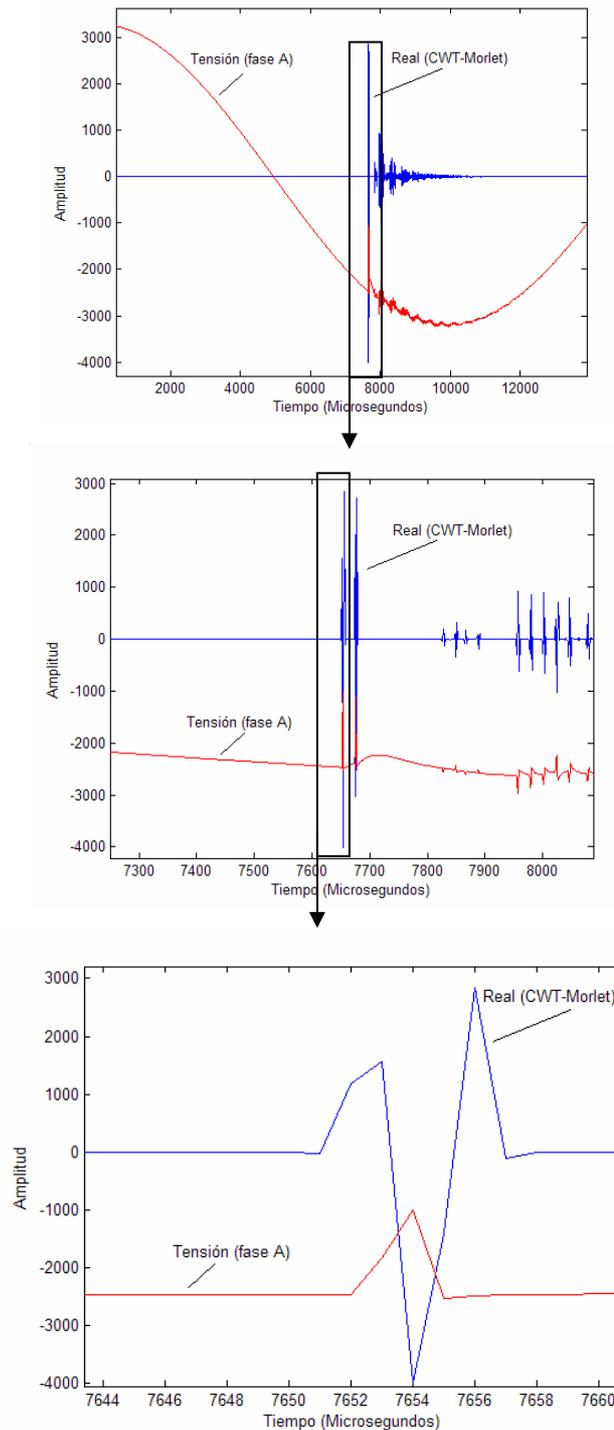


Fig. 4-7. Detalle de la primera singularidad detectada en la señal de tensión.



El “Modulus Maxima” (MM), busca sacar la mejor información disponible de la transformada, desechando las oscilaciones y tomando solo el mayor valor registrado en un intervalo de tiempo definido.

Para mayor precisión matemática, hay que definir el Modulus Maxima:

Para ello, se establece la función $Wf(s,x)$, la transformada wavelet de una función $f(x)$.

- Se define extremo local, a cualquier punto (s_0, x_0) , tal que $(dWf(s_0,x)/dt)$ tiene un cruce por cero en $x = x_0$.

$$\left. \frac{\partial Wf(s_0, x)}{\partial x} \right|_{x=x_0} = 0 \tag{4.2.49}$$

- Se define por tanto “Modulus Maxima” (MM), al valor de $Wf(s_0, x_0)$, en (s_0, x_0) , tal que se cumpla la siguiente relación:

$$|Wf(s_0, x_0 - \Delta x)| < |Wf(s_0, x_0)| > |Wf(s_0, x_0 + \Delta x)| \tag{4.2.50}$$

El procedimiento práctico (programado) para obtener el MM de una señal, se puede resumir en los siguientes pasos:

- Se aplica la transformada a la señal.
- Se levanta una envolvente sobre los coeficientes transformados.
- Se buscan los puntos máximos en un barrido por la señal completa y a cada máximo local se le denomina MM en ese punto.
- La polaridad del MM se determina mediante el primer pico de la parte real de la transformada.

Así, si tomando la última parte de la Fig. 4-8, para seguir con la aplicación a un ejemplo particular, se podría con el valor absoluto de la transformada, trazar una envolvente, tal como se muestra en la Fig. 4-9.

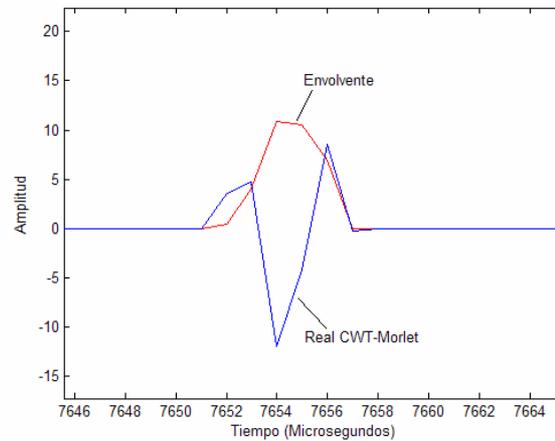


Fig. 4-8. Envolvente promediada con el valor absoluto de la Transformada Compleja.

Con dicha envolvente, se aplica el concepto de buscar el máximo y se obtiene el MM, como se muestra en la Fig. 4-9.

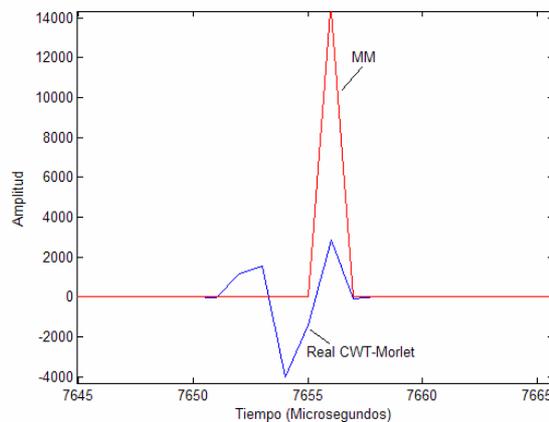


Fig. 4-9. MM de la señal de voltaje (primera discontinuidad)

Y en la Fig. 4-10, se muestra el MM de la señal al completo. En el MM, todos los puntos de la gráfica son cero, excepto en las posiciones del MM, por lo que se reduce en 1/6 los datos que suministran la información de la onda transformada. Esto hace especialmente atractiva esta herramienta para el análisis de ondas como las procedentes de una falta.

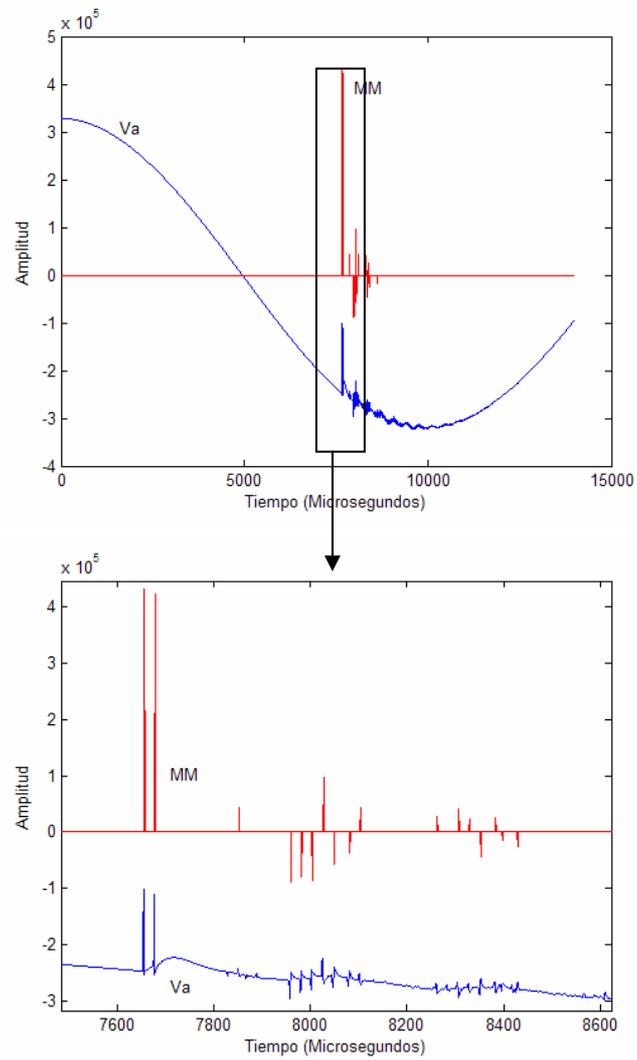


Fig. 4-10. MM de la señal V_a .



4.2.4.- Obtención del valor efectivo (r.m.s.) de una señal, a partir de la descomposición wavelets (utilizando DWT):

Una información importante que tiene amplia utilización en el campo de la calidad de energía y que no deja de ser significativa en aplicaciones de protección eléctrica, es la obtención de valores efectivos (rms), fasores, etc., para señales que están sometidas a condiciones transitorias.

La información obtenida de la transformada de Fourier para estimar el valor efectivo de una señal que posee componentes transitorios significativos, tiene grandes limitaciones [68]. Por ello, es indispensable el uso limitado de la transformada rápida de Fourier (STWFT) para poder subsanar en cierta manera estas deficiencias.

Sin embargo, diversos trabajos como [101], demuestran que la obtención de esta información utilizando la transformada discreta de Wavelet (análisis multi-resolución), es precisa y además puede obtenerse trabajando con ventanas de menos de un ciclo (1/2 ciclo ó 3/4 de ciclo).

La forma de obtener este valor efectivo, es relativamente sencilla y se muestra a continuación, con la Fig. 4-11. Para cada nivel de detalle y aproximación se obtiene un valor efectivo equivalente:

- Para los coeficientes de aproximación: $f_{co\ rms}$
- Para cada nivel de detalle: $f_{di\ rms}$

Tal que, estas funciones $f_{x\ rms}$ quedan definidas de la siguiente forma:

a.- Para el nivel de aproximación:

$$f_{c_0\ rms} = \sqrt{\frac{\|f_{c_0}(t)\|_2^2}{L_{f(t)}}} = \sqrt{\frac{\sum_k c_0(k)^2}{2^J L_{c_0}}} \tag{4.2.51}$$

Donde:

L_{c_0} es el número de puntos de ese detalle.

C_0 son los coeficientes

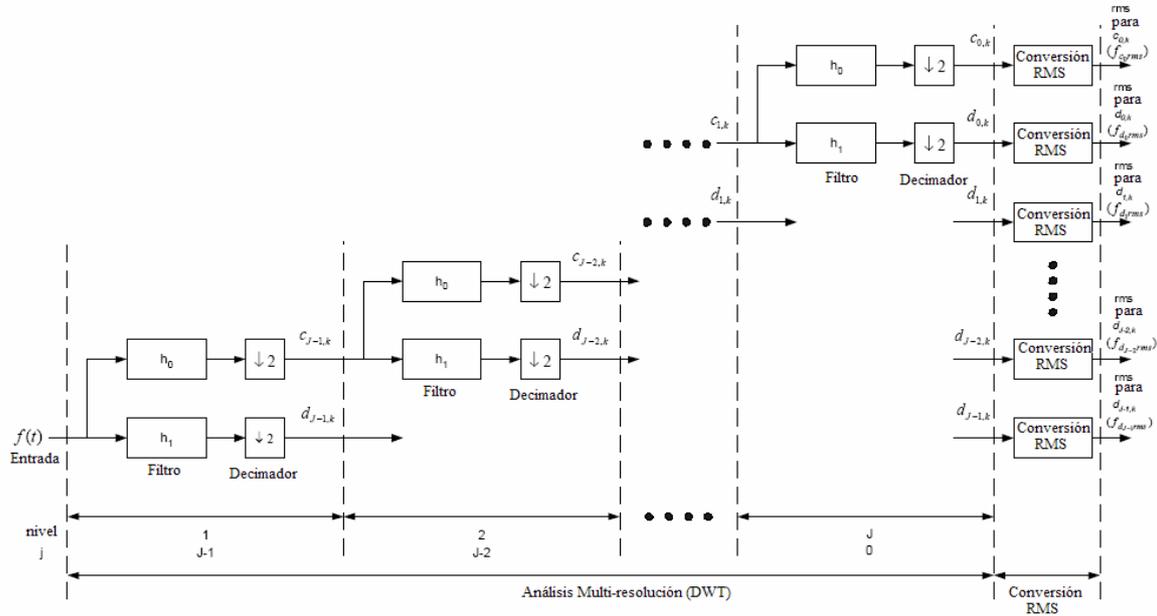


Fig. 4-11. Análisis Multi-resolución, aplicado al cálculo del valor efectivo (RMS)

b.- Para los niveles de detalle j:

$$f_{d_j,rms} = \sqrt{\frac{\|f_{d_j}(t)\|_2^2}{L_{f(t)}}} = \sqrt{\frac{\sum_k d_j(k)^2}{2^{Level} L_{d_j}}} = \sqrt{\frac{\sum_k d_j(k)^2}{2^{J-j} L_{d_j}}} \quad (4.2.52)$$

Donde:

L_{d_j} es la cantidad de puntos para el nivel j.

d_j , son los coeficientes.

Así el valor efectivo total de la onda, puede obtenerse con la siguiente expresión:

$$V_{rms} = \sqrt{f_{co}^2 + \sum_j f_{d_j}^2} \quad (4.2.53)$$

Para una señal de corriente en un sistema con falta, el cálculo del valor rms con el tiempo, se puede obtener gráficamente como se indica a continuación (Fig. 4-12, 4-13 y 4-14), variando el ancho de la ventana considerada (un ciclo y medio ciclo).

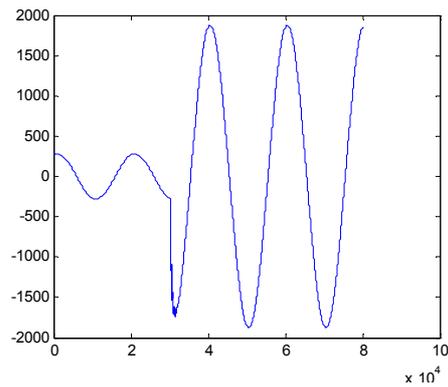


Fig. 4-12. Señal de corriente en el dominio del tiempo.

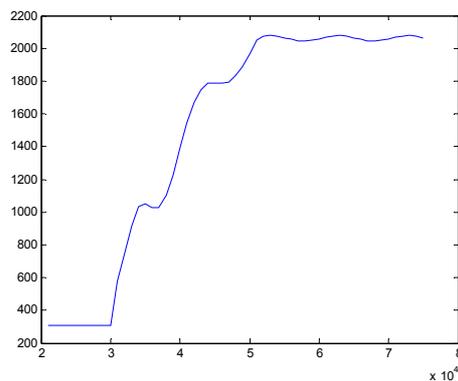


Fig. 4-13. Valor pico (x 1.1) para ventanas de un ciclo.

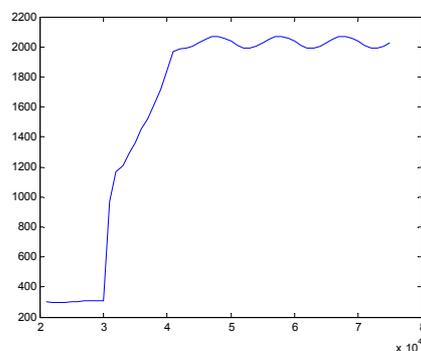


Fig. 4-14. Valor pico (x1.1) para ventanas de medio ciclo.

Se puede observar que se llega más rápidamente al valor efectivo de condición de falta, utilizando ventanas cortas. Esto se debe a la menor utilización de datos pre-falta. Además se puede mejorar el comportamiento ante sobre-estimados, por medio de promedios ponderados entre valor actual y valor pasado, en relaciones variables (30-70%, es el utilizado en las Fig. 4-15 y 4-16).

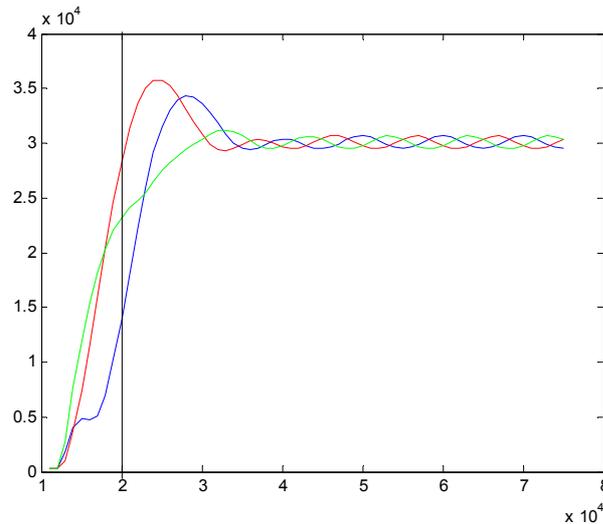


Fig. 4-15. Estimación valor efectivo de las corrientes para una falla trifásica.
Utilizando medio ciclo de ventana.

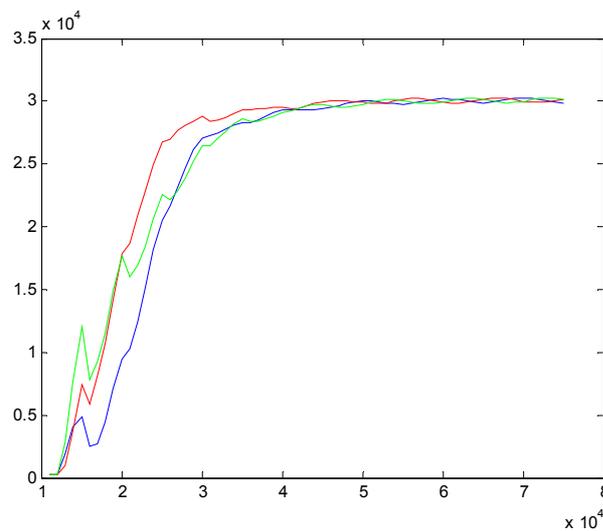


Fig. 4-16. Estimación del valor efectivo ante la misma falla de la Fig. 3-32, pero promediando de forma ponderada los puntos (30-70), en ventanas de medio ciclo.

Y se podría optimizar aún más, si se utilizaran ventanas adaptivas como las planteadas para estimación de impedancia en relés de distancia [53].

En definitiva, la estimación en medio ciclo posterior a la falla del valor efectivo de la corriente, es una ventaja para ser utilizada en los algoritmos de protección y/o localización de faltas.

A continuación se presentan las estimaciones del valor efectivo para un caso particular y todos los tipos de falta transversal posible (FAT, FBT, FCT, FAB, FBC, FCA, FABT, FBCT, FCAT, FABC).

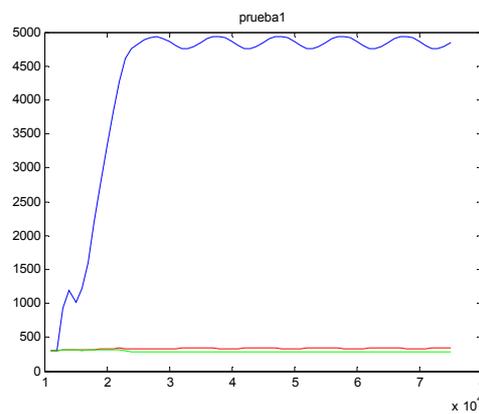


Fig. 4-17. Estimación valor efectivo. Falta AT.

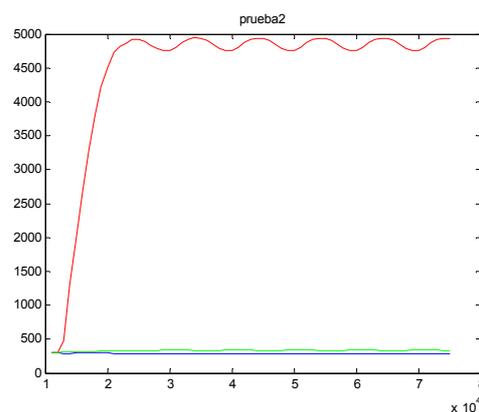


Fig. 4-18. Estimación valor efectivo. Falta BT.

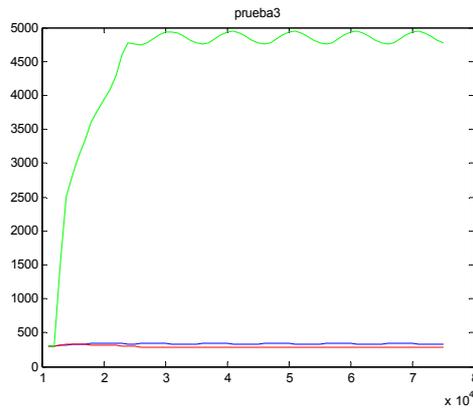


Fig. 4-19. Estimación valor efectivo. Falta CT.

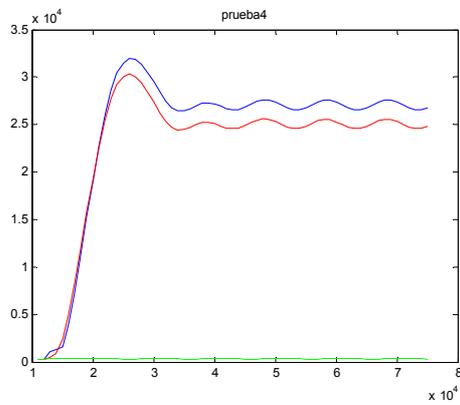


Fig. 4-20. Estimación valor efectivo. Falta ABT.

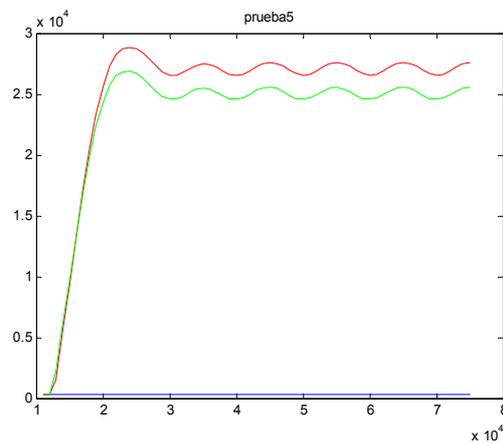


Fig. 4-21. Estimación valor efectivo. Falta BCT.

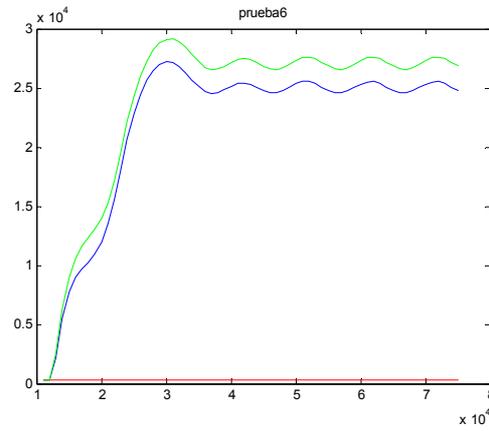


Fig. 4-22. Estimación valor efectivo. Falta CAT.

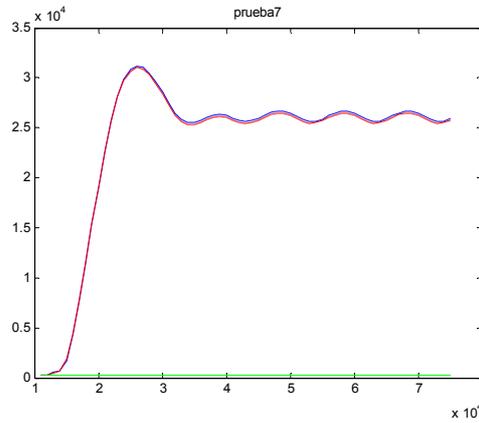


Fig. 4-23. Estimación valor efectivo. Falta AB.

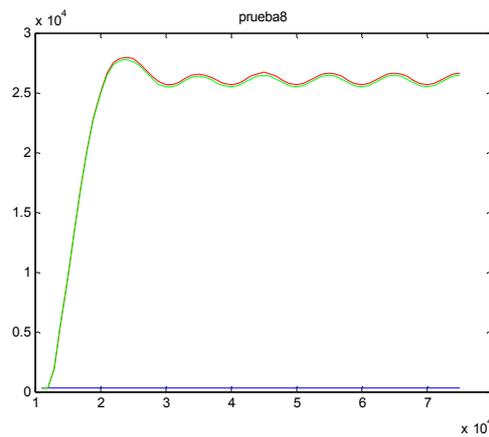


Fig. 4-24. Estimación valor efectivo. Falta BC.

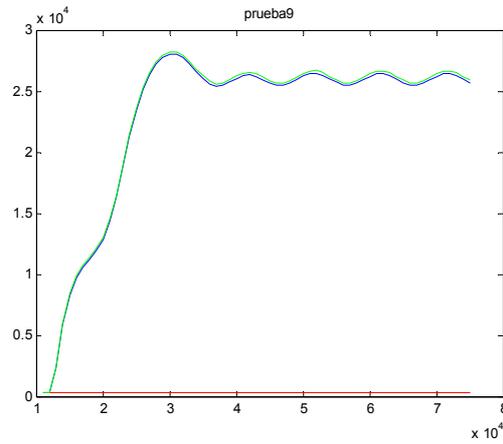


Fig. 4-25. Estimación valor efectivo. Falta CA.

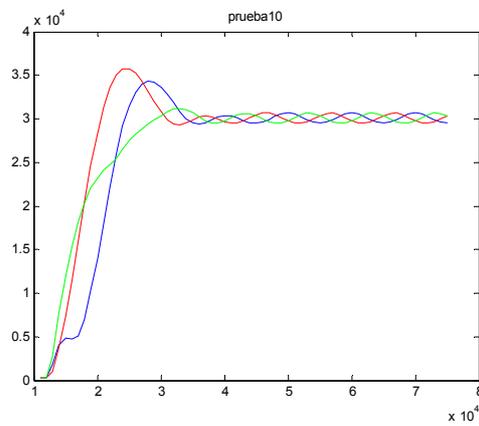


Fig. 4-26. Estimación valor efectivo. Falta ABC.



4.2.5.- Estimación de Cantidades Fasoriales para tensiones y corrientes, utilizando transformada Wavelets.

La estimación de fasores es clásica y clave para la mayoría de sistemas de protección y localización en sistemas de alta tensión, pues se basan en la estimación de la impedancia vista desde la barra de medición.

Para poder obtener la impedancia, es necesario poseer los fasores de tensión y corriente que se correspondan.

Hay muchas maneras para la obtención de estas cantidades, pero la idea del presente punto es presentar aquellas que han sido desarrolladas, utilizando la transformada wavelets como herramienta.

Estos métodos pueden ser clasificados según el tipo de transformada que utilizan.

- a.- Transformada Discreta.
- b.- Transformada continua.

El común denominador de ambas metodologías, es que se utiliza la transformada wavelet como un filtro para obtener de la mejor forma posible la componente fundamental de la señal a analizar.

Y para la obtención de los fasores, las metodologías planteadas coinciden en su gran mayoría con las utilizadas con transformaciones convencionales como las de Fourier, filtros de Walsh, Kalman, etc.

Así que aquí se van a plantear las metodologías implementadas en algunos trabajos [53, 68, 102].

4.2.5.a.- Utilizando la Transformada Discreta:

El análisis multi-resolución se basa en la aplicación sucesiva de filtros discretos pasa-bajos (h_0) y pasa-altos (g_0), por lo que en determinado nivel de descomposición, los coeficientes de aproximación arrojarán una forma de onda cuyos componentes de frecuencia están alrededor del fundamental. Así si por ejemplo se trabaja a una tasa de muestreo de 960 Hz, (en un sistema con frecuencia base de 60 Hz) los niveles de descomposición posibles serían los mostrados en la Fig. 4-27.

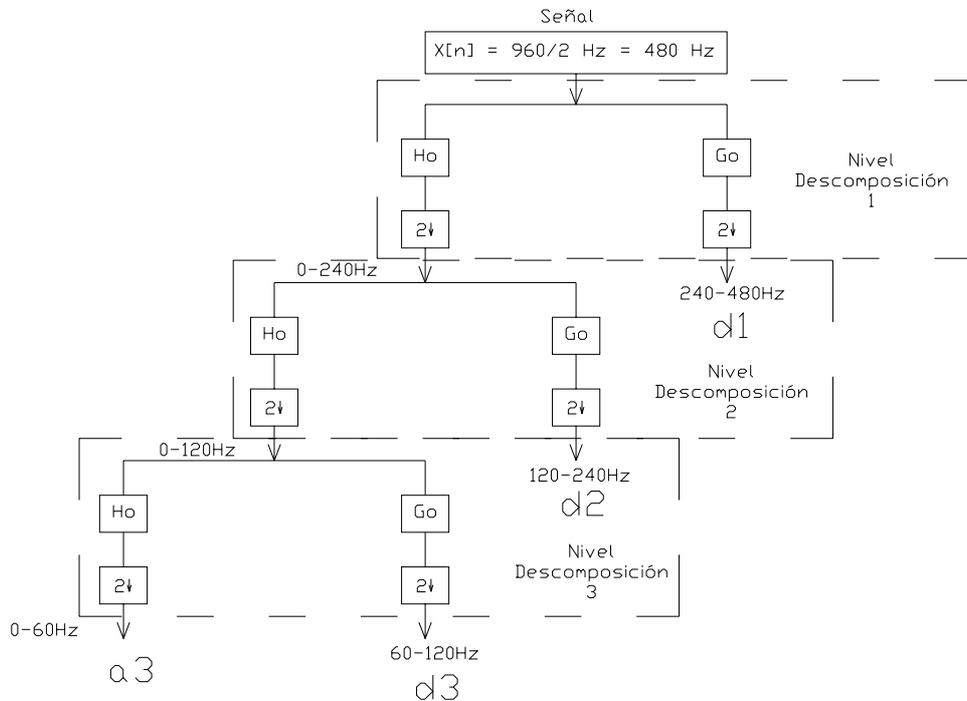


Fig. 4-27. Descomposición MRA de una señal a 960 Hz

Así que para la estimación fasorial, puede trabajarse con la aproximación obtenida del segundo nivel de descomposición (a_2 : 0-120 Hz) o de forma más precisa aunque con mayor carga computacional, la aproximación obtenida del tercer nivel de descomposición (a_3 : 0-60 Hz).

Una vez conseguida la señal a_2 ó a_3 , el cálculo del favor se puede realizar utilizando una señal de referencia unitaria y de frecuencia fundamental, basándose en la teoría fundamental de los vectores.

La señal de referencia debe tener la misma cantidad de muestras que la señal descompuesta (a_2 ó a_3). Esta señal de referencia va a ser denominada R_1 y todas las cantidades eléctricas deberán ser comparadas angularmente con la misma señal para establecer de forma correcta el ángulo de los fasores respectivos.

Así, conocidos a_2 y R_1 como vectores, se puede determinar el ángulo entre ellos, con la siguiente propiedad:

$$\theta = \cos^{-1} \frac{(R_1 \bullet a_2)}{|R_1| |a_2|} \quad (4.2.54)$$

Donde:

$(R_1 \bullet a_2)$, es el producto punto de dos vectores.

$|S|$, es la norma del vector.

Esto puede demostrarse, pues dados dos vectores v y w de la misma longitud (Fig 4-28), la relación de su producto punto en el sentido geométrico vendría representada por la función:

$$(v \bullet w) = |v| |w| \cos(\theta) \quad (4.2.55)$$

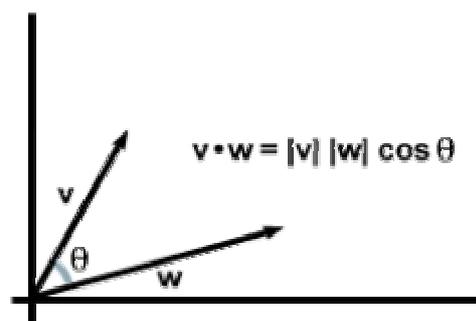




Fig. 4-28. Representación geométrica del producto punto entre dos vectores.

Donde, sean:

$$v = (v_1, v_2, \dots, v_n) \quad (4.2.56)$$

$$w = (w_1, w_2, \dots, w_n) \quad (4.2.57)$$

Su producto punto sería:

$$(v \cdot w) = (v_1 \cdot w_1, v_2 \cdot w_2, \dots, v_n \cdot w_n) \quad (4.2.58)$$

Y sus normas, corresponderían a:

$$|v| = \sum_{j=1}^n |v_j| \quad (4.2.59)$$

Una vez obtenido el valor del ángulo θ , la estimación de la magnitud, puede ser realizada de dos formas:

- Estimando el valor efectivo (rms) de la señal, según el procedimiento descrito anteriormente.
- Estimar la magnitud del vector a_2 ó a_3 , utilizando una propiedad geométrica similar a la del cálculo del ángulo.

La primera alternativa, ya ha sido ampliamente descrita en el aparte anterior y la segunda, se basa en crear una segunda señal de referencia (R2), de magnitud unitaria, pero con un ángulo θ , igual que a_2 ó a_3 .

Este vector R2, al igual que el R1, debe tener la misma longitud que los vectores resultantes de la aproximación en el segundo o tercer nivel de descomposición (a_2 ó a_3).



Y la magnitud A , de dicho vector sería definida por la siguiente relación:

$$A = \frac{|1||a_2|}{|R_2|} \quad (4.2.60)$$

De esta forma, es relativamente sencillo obtener los fasores de las señales de tensión y corriente involucradas, con una buena precisión. Adicionalmente es muy sencillo de implementar en un algoritmo de programación.

Hay otras alternativas igual de válidas pero menos precisas, que pueden buscar para las señales a_2 ó a_3 , los cruces por cero y referenciarlas angularmente al inicio de la ventana de muestreo. Si bien es mucho más sencillo de implementar, el algoritmo que permita obtener con precisión el primer cruce por cero de la señal es algo más complicado, pues la precisión depende de cumplir correctamente este objetivo.

4.2.5.a.- Utilizando la Transformada Continua:

En este trabajo se le ha dado especial atención al uso de la transformada continua compleja, para el análisis de señales y esto no solo tiene que ver con la obtención de la información de los componentes de alta frecuencia (transitorios y onda viajera), sino también con la obtención de fasores para la estimación de impedancias u otros tipo de análisis basados en esta información en el dominio de la frecuencia, en especial cuando la onda tiene una variación producto de un evento como una falta en el sistema eléctrico de potencia [68].

De la misma forma que lo planteado en el punto anterior, la transformada continua compleja, funge como un filtro en este caso digital de la señal para obtener su componente fundamental y posteriormente analizarla.

Al aplicar la transformación con la selección adecuada de los parámetros F_b y F_c de la función madre de Morlet,

$$\psi(x) = \sqrt{\pi f_b} e^{2i\pi f_c x} e^{-\frac{x^2}{f_b}} \quad (4.2.61)$$

Donde:

F_b , es el ancho de banda, y

F_c , es la frecuencia central de la función.

Las componentes reales e imaginaria, superpuestas a una señal de referencia, pueden verse en la Fig. 4-29. Con un ajuste como $F_c = 200$ Hz y $F_b=1$, puede obtenerse una buena representación de las señales con frecuencia fundamental del orden de 50 – 60 Hz.

La ventaja de trabajar con este tipo de transformaciones es que la función madre (B-Spline o C-Morlet – Fig. 4-30), tienen la propiedad de ser simétricas en frecuencia y bi-ortogonales.

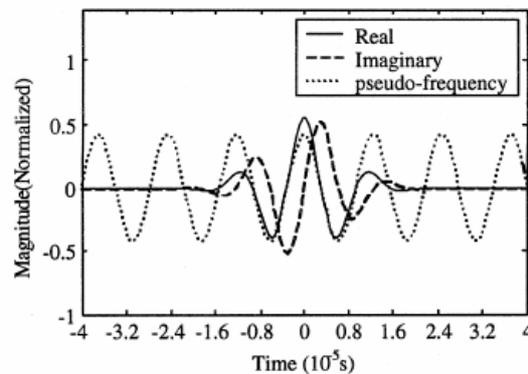


Fig. 4-29. Wavelet Morlet Compleja, con $F_c = 80$ kHz ; $F_b= 1$ [90].

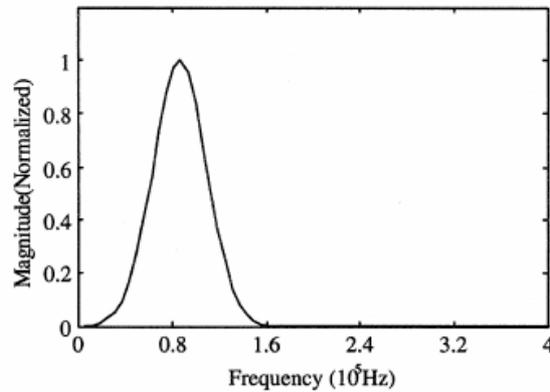
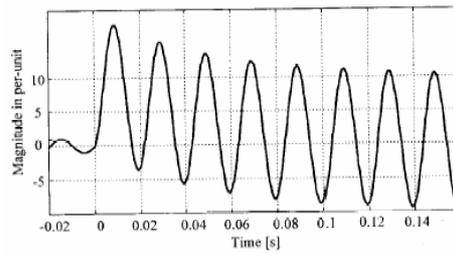


Fig. 4-30. Respuesta en frecuencia de la Wavelet Morlet Compleja [90].

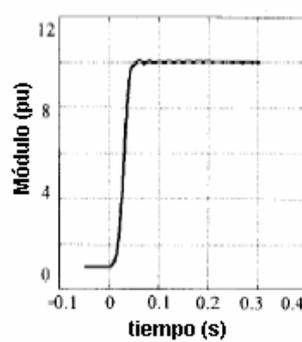
Y la estimación de la magnitud, tanto para la parte real como para la parte imaginaria de la transformada, puede ser determinada utilizando los principios expuestos en el punto anterior y posteriormente el fasor se expresa directamente como:

$$V = V_{\text{real}} + j V_{\text{imaginario}} \quad (4.2.62)$$

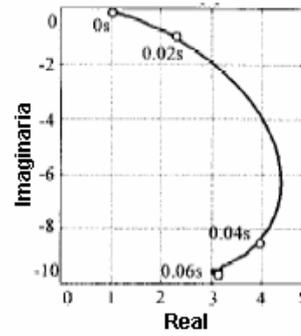
Lo mismo para las corrientes. Y un ejemplo de esta aplicación se presenta en la Fig. 4-31. La determinación posterior de las impedancias respectivas, queda directamente establecida con la relación entre los fasores anteriormente determinados y con el tipo de falta que debe ser previamente clasificada.



(a)



(a)



(c)

Fig. 4-31. Ejemplo del uso de la CCWT para la obtención de fasores de Voltaje y Corriente. (a) señal en el dominio del tiempo, (b) Módulo de la Transformada y (c) relación entre parte real y parte imaginaria de la transformada.



4.3.- Algoritmo para la detección de Faltas:

El primer paso para iniciar cualquier algoritmo de protección o localización de faltas en un sistema eléctrico de potencia, debe ser la detección del evento.

El criterio a implementar para esta tarea puede ser muy variado, dadas las técnicas que pueden plantearse a este respecto: (ajuste definido, ajuste adoptivo o por reconocimiento de patrones).

Sin embargo, es en este aspecto, que la WT tiene la ventaja por su alta capacidad de detectar singularidades (cambios en la señal).

En esta etapa, no se necesita mayor precisión en cuanto a clasificar fases o inclusive identificar si se trata de falta o de alguna otra maniobra; lo importante es la rapidez para detectar cualquier cambio en la señal muestreada (en este caso las corrientes como variables más sensibles a verse modificadas en caso de falta).

Para ello, hay varias alternativas:

a.- La más sencilla, corresponde a aplicar la descomposición de la DWT, extrayendo la información relativa a los componentes de alta frecuencia de las corrientes de fase y el criterio de detección es la superación de un valor umbral preestablecido:

$$| WT_{\max}(Ia) | \text{ ó } | WT_{\max}(Ib) | \text{ ó } | WT_{\max}(Ic) | > N_{aj} \quad (4.3.1)$$

Con, N_{aj} , valor real determinado empíricamente para el sistema particular.

Generalmente se asocia al primer o segundo detalle de descomposición y podría utilizarse prácticamente cualquier función base real o compleja (o wavelet madre); sin embargo, las más comunes son: db4, B-Spline.



b.- En función de reducir la cantidad de señales a procesar por la WT, se puede trabajar en vez de las corrientes de fase, con las componentes modales (específicamente los modos aéreos α y β), ya definidos en el aparte 4.2.

Y el criterio de selección, sería:

$$| WT_{\max}(I\alpha) | \text{ ó } | WT_{\max}(I\beta) | > M_{aj} \quad (4.3.2)$$

Donde los modos α y β , están obtenidos respecto a la matriz T_a (fase A).

Y M_{aj} , valor real determinado empíricamente para el sistema particular.

c.- Trabajando con las componentes regresivas y progresivas de las señales de la corriente y voltaje en el dominio modal. Esta opción presenta dos vertientes: la que utiliza las cantidades superpuestas y la que trabaja con los fasores. El inconveniente es la necesidad de trabajar con voltajes y corrientes a la vez, lo que incrementa el uso computacional y el tiempo de decisión.

Así, en la primera vertiente, se tiene que la componente superpuesta de la señal, corresponde directamente a la descomposición de nivel de detalle 1 o 2 de la DWT (componentes de alta frecuencia):

$$\Delta V_m(t) = DWT(V_m(t)) \quad (4.3.3)$$

$$\Delta I_m(t) = DWT(I_m(t)) \quad (4.3.4)$$

con $m = \alpha, \beta$ y 0.

Y las cantidades específicas de interés :

$$S1_m = \Delta V_m(t) + Z_m \Delta I_m(t) \quad (4.3.5)$$



$$S2_m = \Delta V_m(t) - Z_m \Delta I_m(t) \quad (4.3.6)$$

con Z_m : Impedancia de onda modal.
 m , corresponde al modo de interés $(\alpha, \beta, 0)$

El criterio de detección, puede ser variado y empírico y una de sus opciones es:

$$|S1_m(t)| \text{ ó } |S2_m(t)| > TH_{aj}. \quad (4.3.7)$$

Con, TH_{aj} , valor real determinado empíricamente para el sistema particular.

En el segundo caso, no se utiliza de forma directa la TW, sino que se trabaja con los fasores de las corrientes y voltajes. El trabajar con fasores, tiene la ventaja de que la descomposición modal puede llevarse a cabo fácilmente con la matriz compleja de Fortescue, pero tiene el inconveniente del procedimiento matemático para su obtención. En el punto 5.6, se tratará la estimación fasorial, basándose en la TW, bien sea continua o discreta, así como real o compleja. Adicionalmente la propuesta necesita las señales de ambos extremos de la línea.

Suponiendo conocidos dichos fasores, el cálculo de los factores de detección, basado en las componentes progresivas y regresivas es el siguiente:

$$N_m := \frac{1}{2} \cdot \left[(V_{rm} - Z_m \cdot I_{rm}) - e^{(\Gamma_m \cdot L)} \cdot (V_{sm} - Z_m \cdot I_{sm}) \right] \quad (4.3.8)$$

$$M_m := \frac{1}{2} \cdot \left[e^{(-\Gamma_m \cdot L)} \cdot (V_{sm} - Z_m \cdot I_{sm}) - (V_{rm} - Z_m \cdot I_{rm}) \right] \quad (4.3.9)$$



Donde:

Γ_m es la constante de propagación modal

Z_m la impedancia de onda

L la longitud de la línea

V_{rm} , V_{sm} , I_{rm} e I_{sm} : son las cantidades fasoriales de las tensiones y corrientes en cada extremo de la línea y pueden ser obtenidos instante a instante, según los procedimientos ya descritos anteriormente.

m , corresponde al modo de interés $(\alpha, \beta, 0)$

El criterio de detección, es:

$$|N_m| \text{ ó } |M_m| > TH_{aj}. \quad (4.3.10)$$

Para el presente trabajo, se utilizó la opción del punto b, con la matriz de Karrenbauer, pero incorporando el “Modulus Maxima” de las transformadas, bajo el siguiente diagrama de Flujo (Fig. 4-32):

Y la selección del nivel de ajuste M_{aj} , debe llevarse a cabo estudiando la variación de dichos parámetros $(MM | WT(I\alpha) | \text{ ó } MM | WT(I\beta) |)$ para los siguientes escenarios:

- Condición de operación normal del sistema (sin falta)
- Peores escenarios de falta (bajos ángulo de inserción del voltaje, altas resistencias de falta, ubicaciones donde se tenga la menor corriente de falta, tipo de falta, etc.)

Podría mejorarse el criterio si se añadiera algún algoritmo que precisara que el evento detectado corresponde efectivamente a una falta y no a otro tipo de maniobra en el sistema como tomas de carga, energizaciones de bancos de capacitores, descargas atmosféricas que no han producido fallo, etc. Sin embargo, esos criterios no han sido

planteados como objetivo en el presente trabajo y se recomendaría una mayor profundidad en algún trabajo futuro relacionado con el área temática de las protecciones.

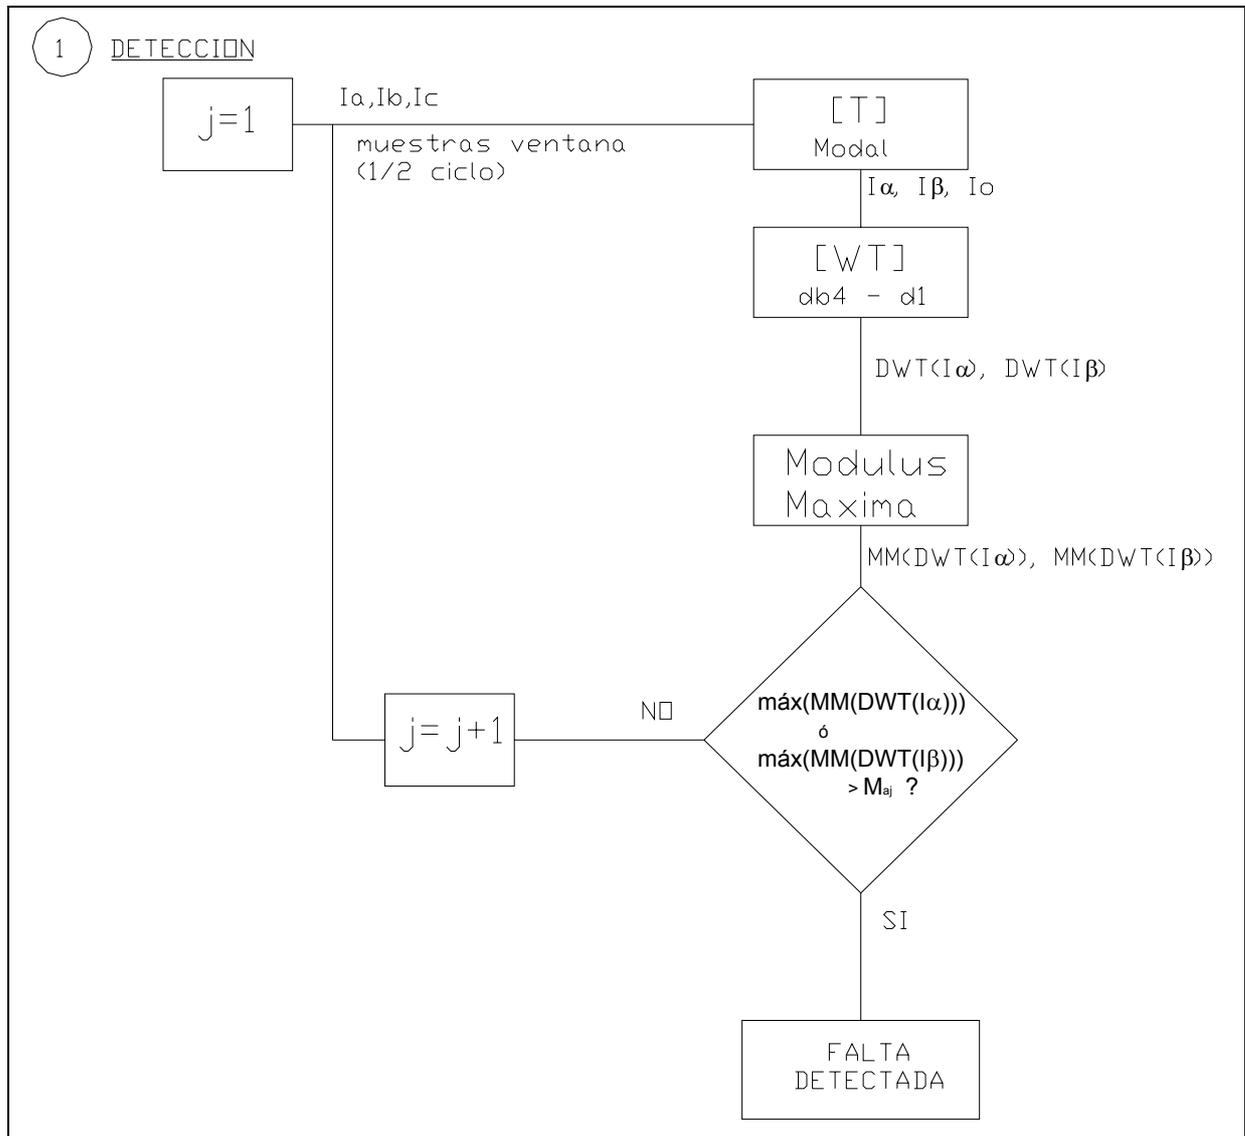


Fig. 4-32. Esquema algrítmico para la detección de la falta.

La capacidad de detectar singularidades de la transformada Wavelet y en particular bajo el criterio planteado en este aparte, para su aplicación en fallos del sistema eléctrico, queda demostrada en la Fig 4-33, la cual no es más que un ejemplo representativo de esto.

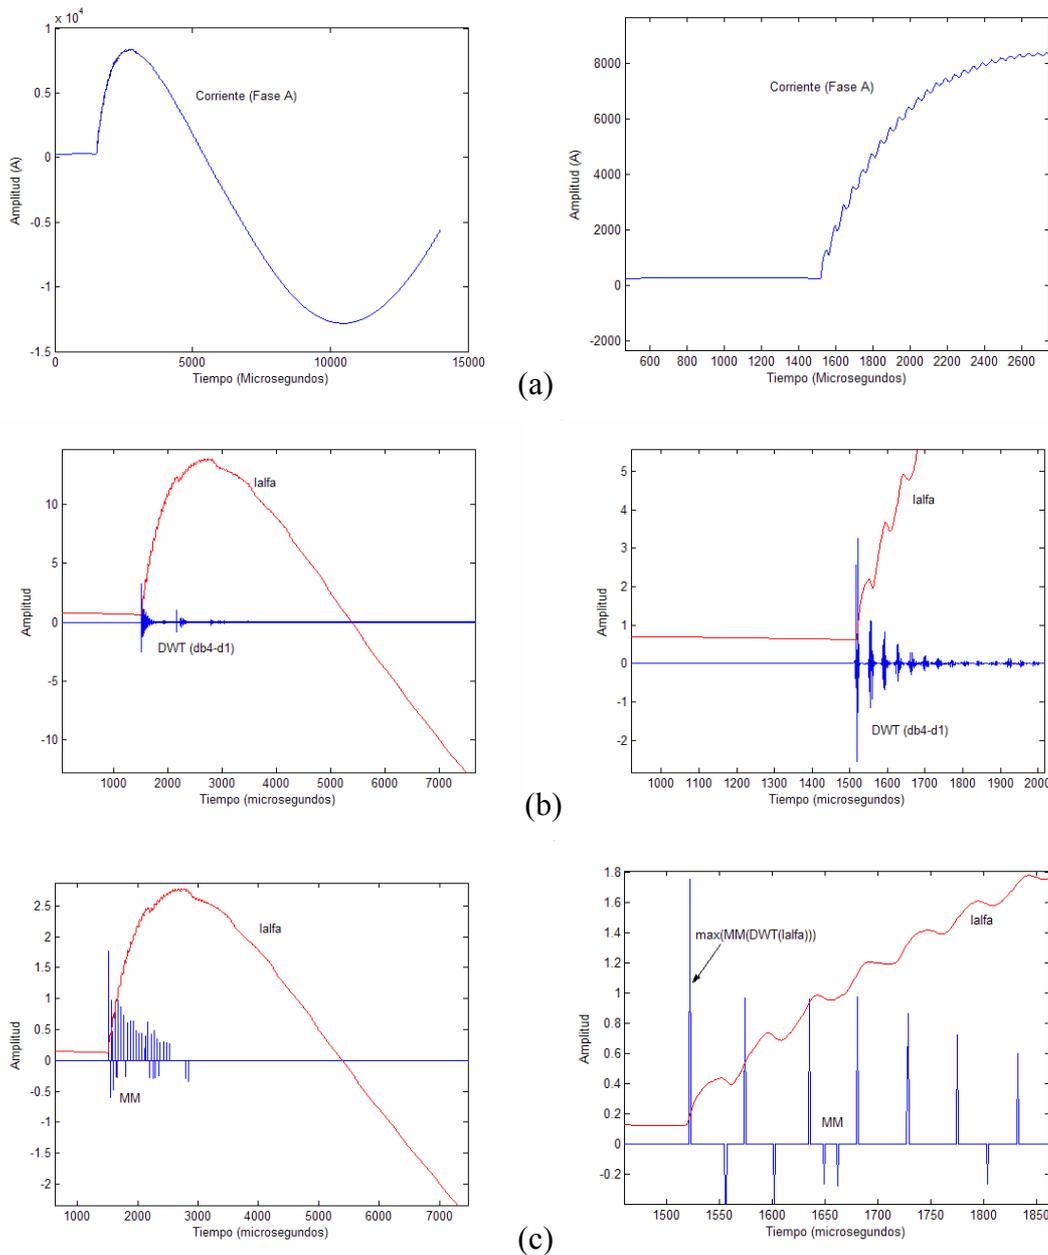
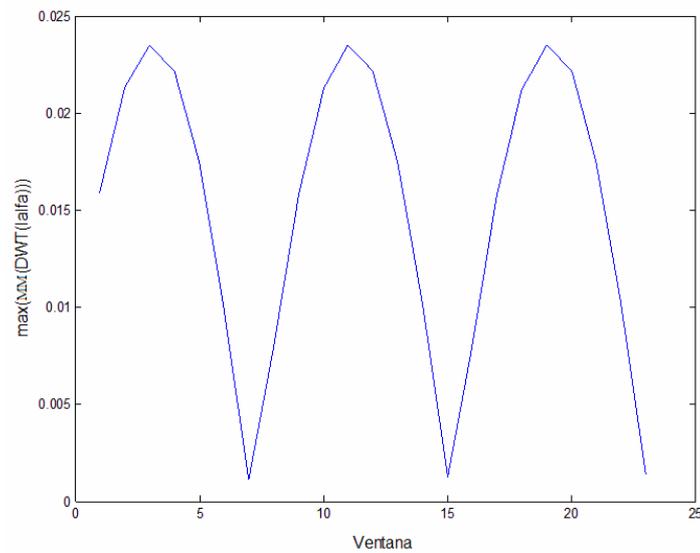


Fig. 4-33. Esquema de obtención de la señal utilizada para la detección (caso modo alfa). (a) Señal de corriente en el dominio del tiempo, (b) Señal modal de la corriente y transformada Wavelet discreta de la misma y (c) Señal modas de la corriente, su Modulus Maxima y el valor máximo del MM ($\max(\text{MM}(\text{DWT}(I_\alpha)))$)

En la Fig. 4-34, se muestra un ejemplo sencillo de la variación de los parámetros de detección en las condiciones del sistema sin falta y ante una falta monofásica a Tierra en la fase A. Se puede notar que existe una variación en un orden de magnitud entre ambas señales, lo cual garantizaría una efectiva detección del evento.



(a) Sin Falla

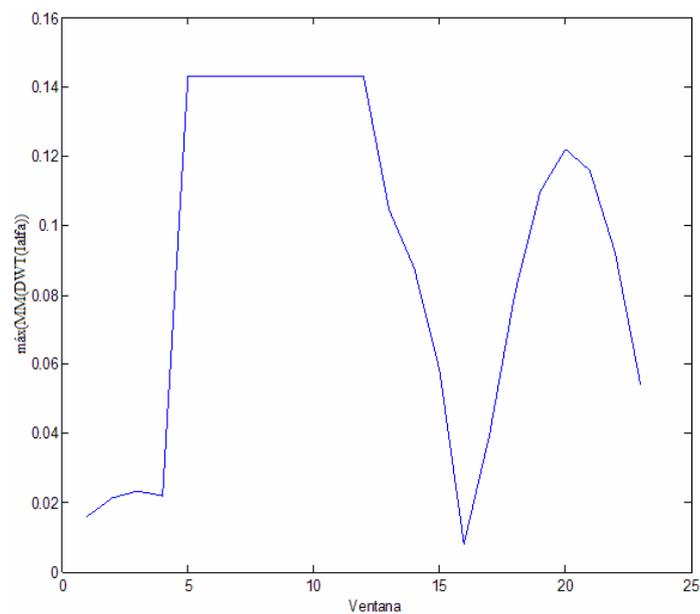
(b) Falla 1 ϕ

Fig. 4-33. Comportamiento de los valores absolutos de los coeficientes.



4.4.- Algoritmo para la clasificación de Faltas:

Una vez que el evento (falta) ha sido detectado, se debe iniciar la tarea de clasificación.

Esta tarea es muy importante, ya que los algoritmos de localización (en todas sus vertientes) dependen de forma directa de las fases involucradas y del tipo de falta (si es a tierra o no).

Al igual que en el caso de detección, se pueden encontrar multitud de alternativas de análisis, basadas en distintas herramientas, trabajando en el dominio de las fases, de la frecuencia, modal, etc.

A continuación se presentan algunas alternativas de algoritmos para la clasificación, basadas en distintas metodologías.

a.- Basado en la clasificación y comparación de los de las cantidades superpuestas de corriente en el dominio modal [116].

Para ello, se utiliza la información de los índices de clasificación provenientes del análisis por componentes simétricas, pero utilizando la matriz de transformación de Karrenbauer, referida a la fase a.

Así, para distintos tipos de faltas, se tiene:

- Falta 1f en la Fase A:

$$I_0 = I_\alpha = I_\beta \quad (4.4.1)$$

- Falta 1f en la Fase B:

$$I_0 = -I_\alpha ; I_\beta = 0 \quad (4.4.2)$$



- Falta 1f en la Fase C:

$$I_0 = -I_\beta ; I_\alpha = 0 \quad (4.4.3)$$

Y resumiendo, se puede llegar a la siguiente tabla comparativa (Tabla I).

Tabla I. Características de las faltas en índices modales.

Tipo de Falta	Fase Fallada	I_0	I_α	I_β
Falta 1f	A	I_a	I_a	I_a
	B	I_b	$-I_b$	0
	C	I_c	0	$-I_c$
Falta 2f	AB	0	$2I_a$	I_a
	BC	0	$-I_b$	I_b
	CA	0	I_c	$2I_c$
Falta 2f-T	AB	I_a+I_b	I_a-I_b	I_a
	BC	I_b+I_c	$-I_b$	$-I_c$
	CA	I_c+I_a	I_a	I_a-I_c
Falta 3f	ABC	0	I_a-I_b	I_a-I_c

Cabe resaltar como hecho curioso, que todas las faltas pueden ser clasificadas de esta manera, pues nunca se repite un orden de índices. Esto solo ocurre para la matriz de Karrenbauer.

En función de esto se puede desarrollar un algoritmo basado en la comparación entre los coeficientes de DWT tanto de las corrientes de fase, como el de las componentes modales. Para ello, se plantea el uso del “Modulus Maxima” sobre los coeficientes de la transformada. Este concepto es muy sencillo y lo que busca es la eliminación de ruido, sobresaliendo únicamente la información relevante de la señal descompuesta.

Sin embargo, esta alternativa presenta como desventajas fundamentales, la gran cantidad de información que es necesaria clasificar, pues son más de 10 índices en 10 comparaciones que deben ser elaborados para la clasificación y además si se trabaja con el MM de una componente modal para detalles de alta frecuencia, se tiene el problema del ángulo de inserción de la tensión, que puede hacer algunos índices tan pequeños que podrían ser comparados con un cero, lo que acarrearía un error de clasificación.

Esta herramienta podría ser mejorada si la comparación se hiciese mediante el entrenamiento de redes neuronales generalizables como una de retropropagación o una de base radial con ajuste exacto, o si se trabajase con cantidades fasoriales.

Esta última alternativa, se describe en la siguiente metodología

b.- Uso de las componentes progresivas y regresivas, mediante fasores.

En [74], se utiliza la matriz de Clark, para encontrar una relación para clasificar las faltas, tal como se indica en la tabla II.

Tabla II. Relación modal – fase [74]

Fault types		LG			LLS			LLG			3LS/3LG	
Basis	Fault detection index	ag	bg	cg	abs	bcs	cas	abg	bcg	cag	abcs	abeg
Phase a	M_a^0	1	1	1	0	0	0	1	1	1	0	0
	M_a^{α}	1	1	1	1	0	1	1	1	1	1	1
	M_a^{β}	0	1	1	1	1	1	1	1	1	1	1
Phase b	M_b^0	1	1	1	0	0	0	1	1	1	0	0
	M_b^{α}	1	1	1	1	1	0	1	1	1	1	1
	M_b^{β}	1	0	1	1	1	1	1	1	1	1	1
Phase c	M_c^0	1	1	1	0	0	0	1	1	1	0	0
	M_c^{α}	1	1	1	0	1	1	1	1	1	1	1
	M_c^{β}	1	1	0	1	1	1	1	1	1	1	1

Nota: Se modifica la matriz de transformación respecto a la fase a, b y c y para establecer el valor binario de 0 ó 1, es que la cantidad M_{ϕ}^m supere un valor de ajuste.

A partir de los valores obtenidos, se desarrolla el siguiente esquema lógico (Fig. 4-34). El valor de M_{ϕ}^m , es el indicado en la ecuación (4.4.4).

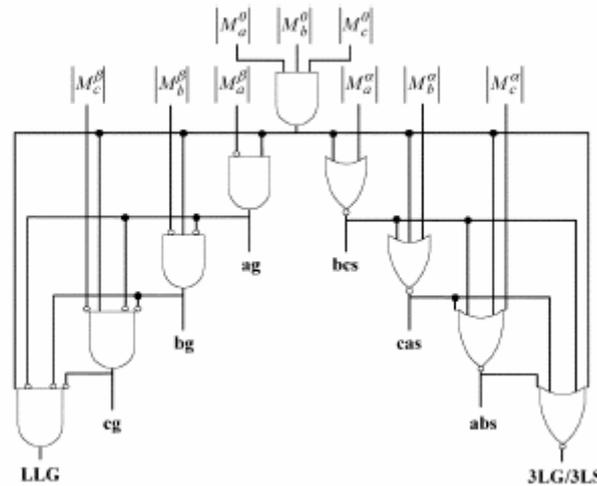


Fig. 4-34. Esquema lógico para clasificación [74]

Donde:

$$M_{T\phi}^m = \frac{1}{2} \cdot e^{-\Gamma_{T\phi}^m} [V_{T\phi}^m + Z_{T\phi}^m \cdot I_{T\phi}^m] \quad (4.4.4)$$

Con:

Γ : constante de propagación modal.

Z: Impedancia de onda modal.

$m = \alpha, \beta, 0$

Tf = Ta, Tb y Tc (fase de referencia en la matriz de transformación)

La desventaja de esta metodología radica en que tal como se plantea en [74], es necesario manejar la información de los dos extremos de la línea y esta data debe ser en fasores sincronizados vía GPS (PMU).

c.- Clasificación utilizando comparaciones de magnitudes de los coeficientes de wavelet y redes neuronales del tipo probabilístico.

Como último método se plantea el uso de la información mezclada de alta y baja frecuencia que puede ser obtenida con los coeficientes de descomposición de la transformada Wavelet.

Al utilizar la información de ambos componentes, tiene la ventaja de funcionar correctamente tanto para bajos ángulos de inserción de la tensión, como para relativamente altas impedancias de falta. Y adicionalmente al trabajar con una red neuronal, se permite generalizar las desviaciones que puedan tener estos coeficientes de comparación al tener variaciones en el sistema como el nivel de cortocircuito, o cambios de topología.

El planteamiento parte de la definición de las siguientes variables:

Si se tienen, las señales de corriente en el dominio de las fases, I_a , I_b e I_c y se trabaja con una ventana de muestreo de $\frac{1}{2}$ ciclo y se clasifica una vez que ha pasado dicho $\frac{1}{2}$ ciclo desde la detección del evento, tal como se muestra en la Fig. 4-35.

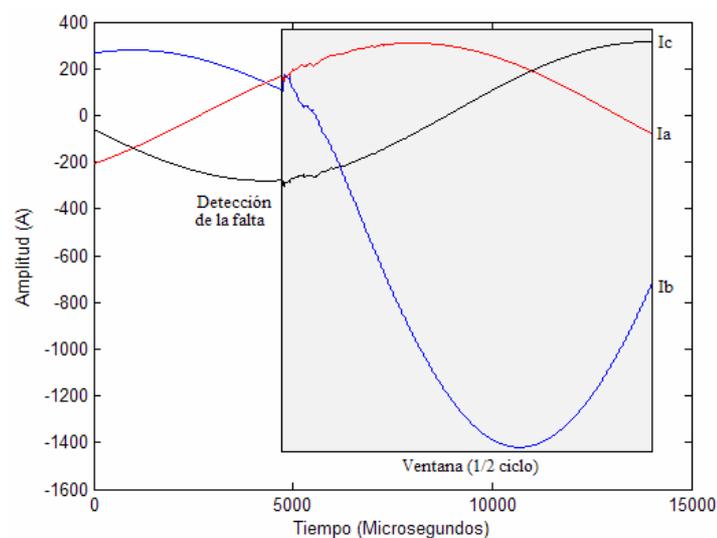


Fig. 4-35. Ventana de trabajo para las señales de corriente en el dominio de las fases.



Si dichas corrientes muestreadas a 1 MHz, se las descomponen utilizando la DWT, db4, se pueden definir las siguientes variables:

Nota: Para esa frecuencia, se dispone de 12 niveles de descomposición.

$$c_1 = \sum_j |d_j^1|^2 \quad (4.4.5)$$

$$c_2 = \sum_j |d_j^5|^2 \quad (4.4.6)$$

$$c_3 = \sum_j |d_j^{10}|^2 \quad (4.4.7)$$

Donde:

d^n : son los coeficientes de detalle para el nivel de descomposición n .

j : es la cantidad de coeficientes para ese nivel de detalle.

$$c_c = \sum_{i=1}^3 c_i \quad (4.4.8)$$

El coeficiente de clasificación C_c , se determina para cada una de las corrientes y se lleva a por unidad del máximo, es decir:

$$C_{base} = \max(C_c^{I\phi}) \quad (4.4.9)$$

Y el vector resultante de los términos de fase, sería:

$$Vc = \left[\frac{C_c^{Ia}}{C_{base}}, \frac{C_c^{Ib}}{C_{base}}, \frac{C_c^{Ic}}{C_{base}} \right] \quad (4.4.10)$$

Adicionalmente, para incorporar la discriminación de falta a tierra, se incluye un cuarto término de clasificación que viene determinado por la corriente homopolar:

$$I_0 = I_a + I_b + I_c \quad (4.4.11)$$

Pero esta cantidad va a ser llevada a por unidad en función de un factor distinto (formato binario).

$$\begin{cases} C_c^{I_0}{}_{bin} = 1, & \text{si } C_c^{I_0} \geq N_0 \\ C_c^{I_0}{}_{bin} = 0, & \text{si } C_c^{I_0} < N_0 \end{cases} \quad (4.4.12)$$

Donde N_0 , es un valor umbral de detección definido empíricamente para el sistema.

Así el vector final con la información para la clasificación, será:

$$Vc = \left[C_c^{I_0}{}_{bin}, \frac{C_c^{Ia}}{C_{base}}, \frac{C_c^{Ib}}{C_{base}}, \frac{C_c^{Ic}}{C_{base}} \right] \quad (4.4.13)$$

Ese vector va a ser la entrada a la red neuronal.

Un ejemplo de la obtención del vector de entrada, se muestra en la Fig. 4-36.

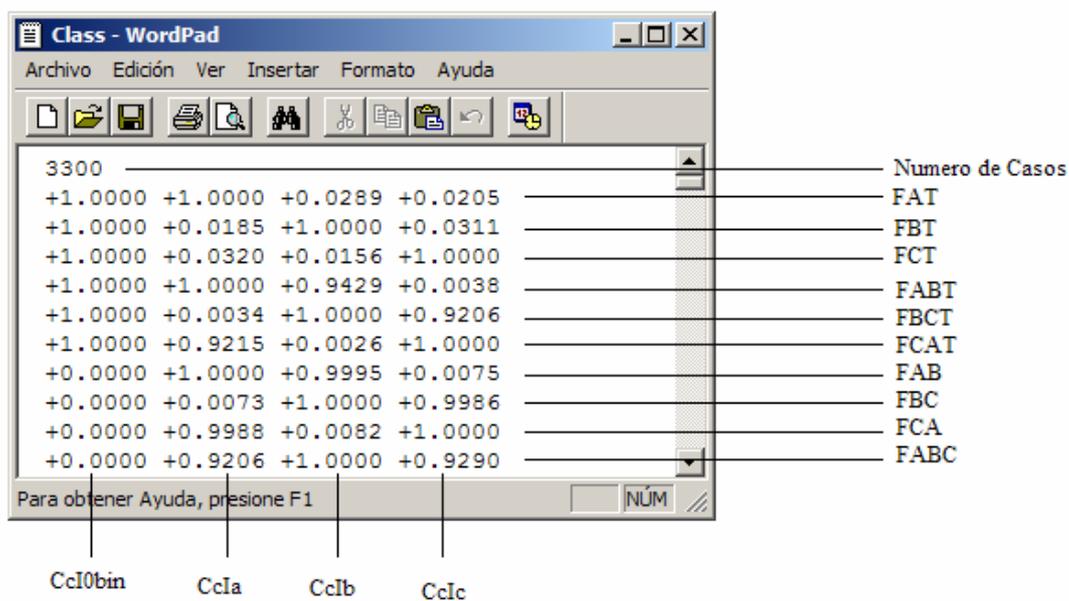


Fig. 4-36. Vector de entrada para la clasificación, obtenido de la simulación en ATP para un caso particular.



La red neuronal seleccionada, es del tipo probabilístico, debido a que la naturaleza de los datos involucrados, lo cual permiten que la clasificación se lleve a cabo de forma adecuada en función de las vecindades con cierta cantidad de casos de entrenamiento referencial.

Dicha red, en cuanto a arquitectura y forma de trabajo, ya fue definida anteriormente y lo que queda para este caso en particular es definir las características específicas de trabajo.

Las dos características más importantes de ser definidas, son:

- Cantidad de neuronas de entrada (función de la cantidad de datos a suministrar).
- Tipo de salida (formato de la salida).

En función del objetivo planteado para la clasificación, el vector de entrada queda definido por (4.4.13), lo que implica que es necesario definir 4 neuronas para la capa de entrada cuyos rangos de validez (al trabajar en por unidad) quedan determinados matemáticamente como $r_s = [0,1]$.

Para la salida, lo que interesa es identificar la fase o fases falladas y si la falta involucra tierra, por lo que una de las alternativas de identificación sería (como es una red probabilística, la salida es una sola y no un vector):

$$\text{Salida} = [\text{FT-FA-FB-FC}], \quad (4.4.14)$$

Por lo que si la falla es por ejemplo FAT, la salida sería, [1100]; si la falta es trifásica (FABC), la salida sería, [0111]. Y así sucesivamente.

El último parámetro a ajustar es H_n (factor de agrupamiento), el cual determina la generalización de la clasificación realizada por la red neuronal. En este caso, se seleccionó que estuviera en el orden de 0.1.

El buen trabajo de la red, va a venir determinado por la cantidad de casos de entrenamiento suministrados, así que mientras mayor cantidad de casos, mejor

funcionará. En general esto depende de las características del sistema (longitud de la línea, complicaciones topológicas, etc.), pero no suele ser inferior a 1500 casos, pues la cantidad de parámetros a tener en cuenta es alta:

- Tipos de faltas (10)
- Localización de la falta (0 -100 %)
- Angulo de inserción de la tensión
- Impedancia de falta

El entrenamiento de la red neuronal, puede ser resumido en la Fig. 4-37.

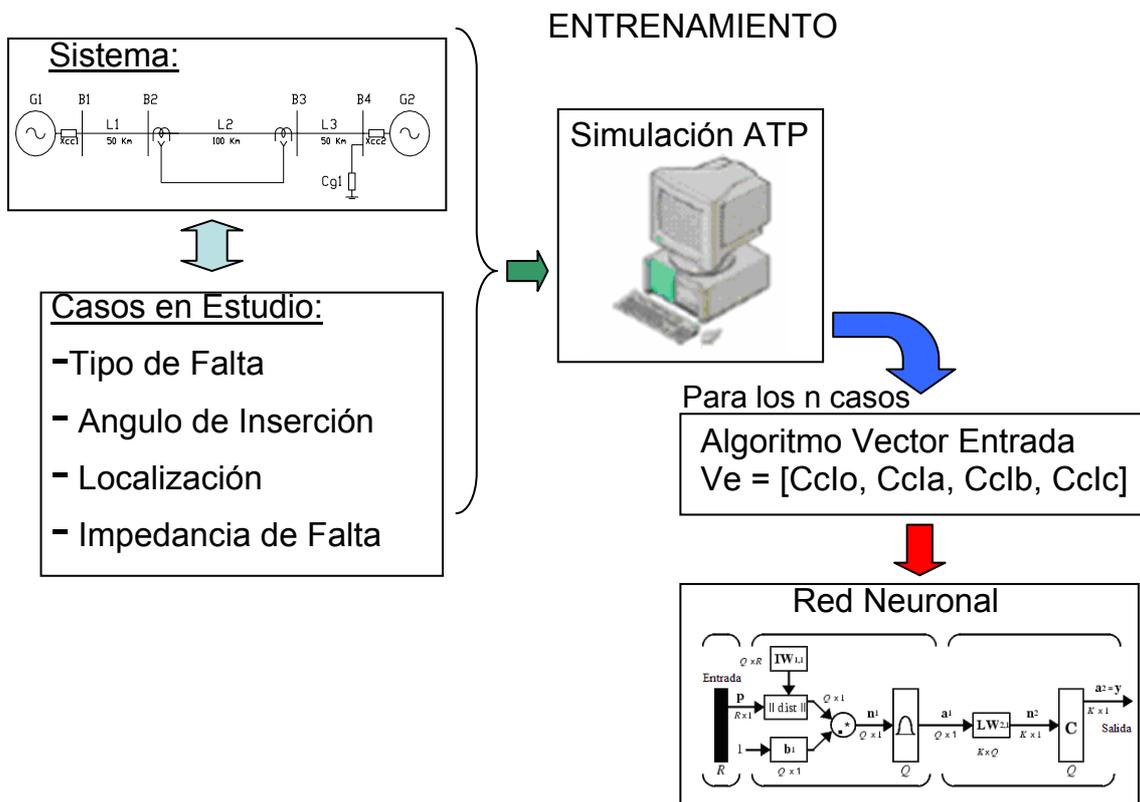


Fig. 4-37. Esquema para la creación y entrenamiento de la red neuronal.



En el siguiente capítulo, se presenta la aplicación del algoritmo, para un sistema de potencia específico, por lo que se definirá con mayor detalle la cantidad de casos de entrenamiento en función de los rangos de variación seleccionados para cada uno de los parámetros que tienen influencia directa sobre esta tarea.

Como herramienta para la modelación de la red neuronal, se utilizó Matlab en su “toolboxes – neural networks”. En este programa, la definición de la red probabilística, viene determinada por la siguiente instrucción:

1.- Definición y asignación con casos de entrenamiento:

```
net1= newpnn (Ve, T, 0.1);
```

Donde:

Net1 es la asignación como nombre de la red.

Ve, es el vector de entrada ya definido (casos de entrenamiento).

T, es la salida predefinida para los casos de entrenamiento.

0.1, es el valor del factor de agrupamiento.

2.- Simulación de la red.

Una vez definida la red, la simulación de un vector de entrada cualquiera, se realiza con la siguiente instrucción:

```
Tc1= sim(net1,VC1);
```

Donde:

Tc1 es la salida de la red.

Net1, fue la designación dada a la red,

VC1 es el vector de entrada a evaluar.

La forma más sencilla de realizar estas instrucciones, es por medio de la herramienta “nntool” de Matlab, en la cual se permite configurar sin mayores complicaciones, el tipo de red, la data de entrenamiento y las simulaciones requeridas.

La metodología empleada en este trabajo corresponde a la última de las herramientas de análisis descritas y el algoritmo de clasificación, podría ser resumido según se indica en la Fig. 4-38.

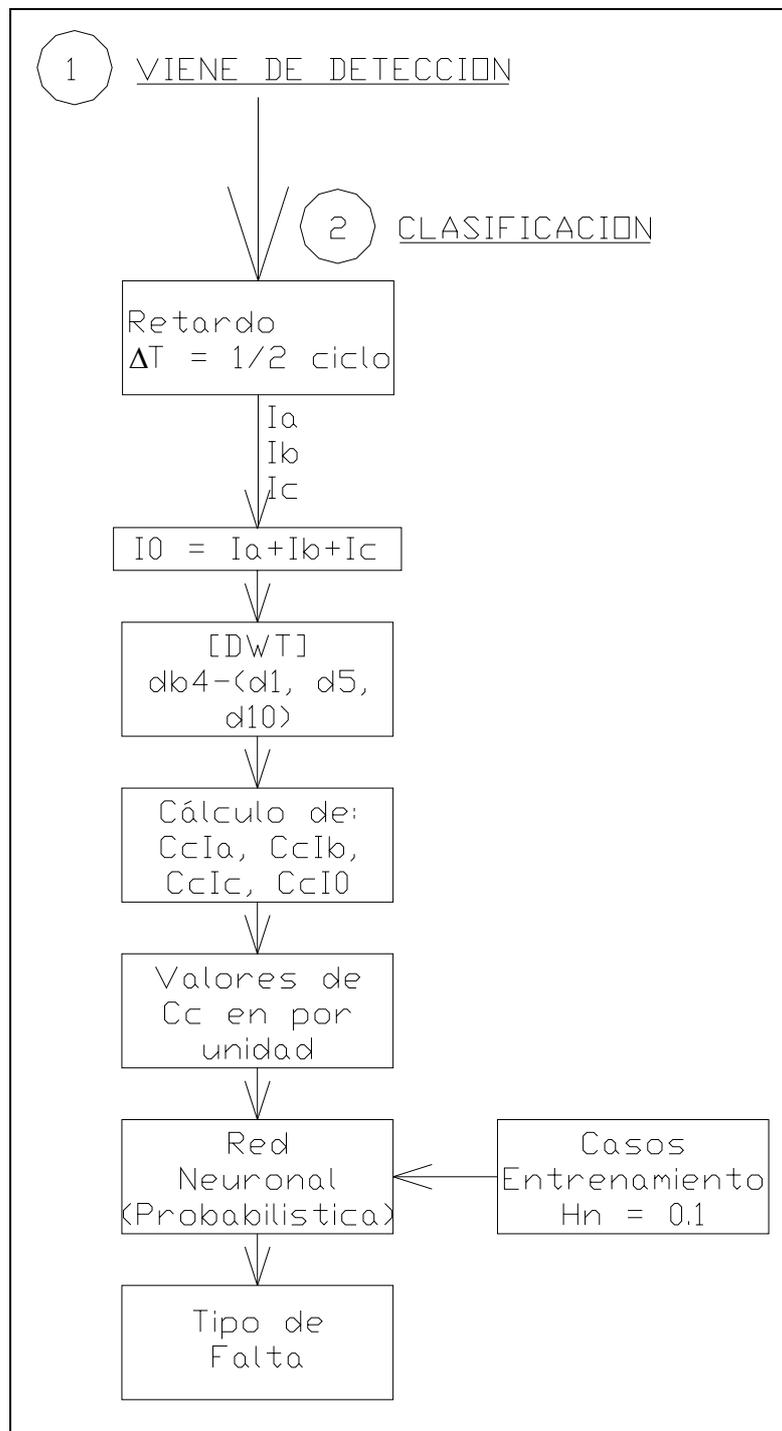


Fig. 4-38. Esquema algorítmico para la clasificación de la falta.



4.5.- Algoritmo para la discriminación direccional de la falta:

En los puntos anteriores, han sido descritos con detalle, los algoritmos de detección y de clasificación de la falta, por lo que lo único que queda pendiente de establecer antes de la localización, es la dirección de la falta. Dado que el algoritmo general desarrollado, parte de la medición en un solo punto de la línea, la determinación de la dirección es importante, para evitar localizar erróneamente faltas que no están en la línea, pues ocurren hacia atrás de la medición.

Para el caso de discriminación de direccionalidad, se han planteado dos ideas interesantes que pueden implementarse con el uso de la transformada Wavelets. La desventaja de estas metodologías es que necesitan todas las señales (tanto tensión como corriente).

a.- Método de la Energía Transitoria.

Se basa en el principio de que la polaridad de la potencia transitoria sirve como indicador de direccionalidad del evento que hace esa solicitud. En la siguiente figura (Fig. 4-39) se demuestra este hecho, con la simulación computacional de un caso particular.

La potencia transitoria se calcula mediante la estimación de las componentes superpuestas de voltaje y corriente; así previo a la falta, el factor es nulo, pues no existen componentes superpuestas. En caso de falta, hay que extraer esa información de las ondas correspondientes; con técnicas convencionales aplicadas en relés numéricos puede ser complicada esta obtención, pues es necesaria una matriz con muestras de las señales previas a la falta y en caso de relés basados en ondas viajeras, esas componentes serían directamente las ondas incidentes en el punto de medición, con el riesgo de grandes errores ante faltas con pequeños ángulos de inserción.

Como alternativa, se plantea el uso de la transformada wavelet, para obtener las componentes de alta frecuencia de las señales de interés.

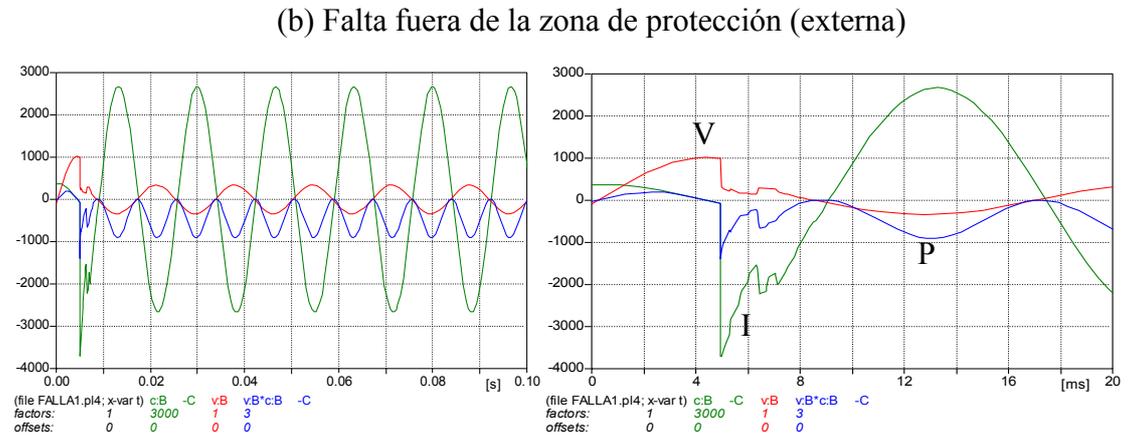
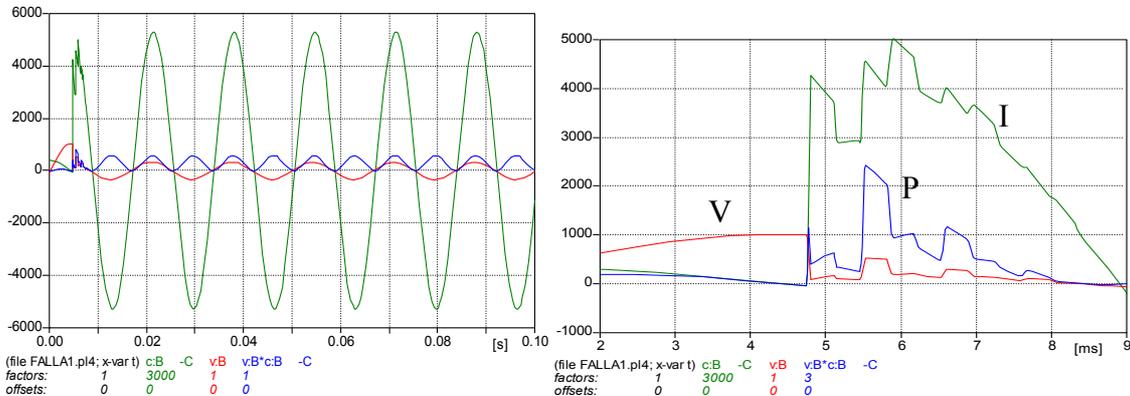
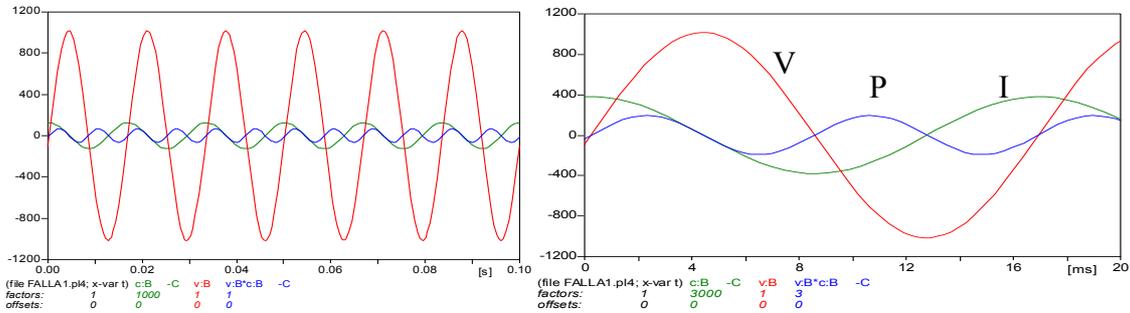


Fig. 4-39. Comportamiento de la potencia en los primeros instantes de ocurrencia de una falta.



Así, en el caso de trabajar con las componentes superpuestas, se puede plantear:

- Energía Transitoria:

$$W_t = \int (\Delta U_a \cdot \Delta I_a + \Delta U_b \cdot \Delta I_b + \Delta U_c \cdot \Delta I_c) dt \quad (4.5.1)$$

Si se trabaja con ventanas y señales muestreadas, la expresión puede ser escrita:

$$W_t = \Sigma (\Delta U_a \cdot \Delta I_a + \Delta U_b \cdot \Delta I_b + \Delta U_c \cdot \Delta I_c) \quad (4.5.2)$$

En este caso, el criterio de direccionalidad, se basa en el signo de W_t .

Si, $W_t > 0$, la falta es hacia delante (según la referencia utilizada)

Si, $W_t < 0$, la falta es hacia atrás.

Este criterio se observa claramente en la Fig. 4-39. Si la falta es interna, durante los primeros instantes, las señales de corriente y voltaje tienen distinto sentido, por lo que la potencia posee valor negativo. Lo contrario sucede en caso de falta externa.

- Componentes de Alta Frecuencia:

El principio es el mismo que el de la energía, solo que en vez de cuantificar una integral en el tiempo de la potencia transitoria, lo que hace es comparar las polaridades de las primeras ondas incidentes de tensión y corriente. Por ende, se establece como criterio:

$$\text{Si, } \Delta U \times \Delta i < 0, \text{ hacia delante} \quad (4.5.3)$$

$$\text{Si, } \Delta U \times \Delta i > 0, \text{ hacia atrás.} \quad (4.5.4)$$



Basándose en esa idea, puede plantearse como fue indicado anteriormente, la obtención de las cantidades ΔU y Δi , a partir de la descomposición de las señales de tensión y corriente, utilizando la transformada wavelet.

Así el cálculo de la potencia instantánea puede llevarse a cabo a través de la expresión:

$$WT(U) \times WT(I) \quad (4.5.5)$$

Dado que se necesita es la comparación de los dos principales picos obtenidos de la descomposición, se aplica el concepto del Modulus Maxima (MM) ya definido anteriormente, sobre los coeficientes de las señales en la ventana de detección (o con algún retardo para aumentar la confiabilidad del planteamiento). Esto puede escribirse, como

$$MM(WT(U)) \times MM(WT(I)) = St \quad (4.5.6)$$

Y el criterio, sería:

Si, $St < 0$, la falta es hacia delante

Si, $St > 0$, la falta es hacia atrás.

b.- Información suministrada por las componentes progresivas y regresivas de las señales transitorias.

A partir de las componentes progresivas y regresivas de la onda viajera originada por la falta, se puede estimar la direccionalidad. Esto se debe a que nuevamente se trabaja con una combinación de la corriente y el voltaje.

En general se plantea en el dominio modal, para trabajar únicamente con el modo de propagación aéreo.



$$F(t) = 0.5 (U_m(t) + Z_o I_m(t)) \quad (4.5.7)$$

$$B(t) = 0.5 (U_m(t) - Z_o I_m(t)) \quad (4.5.8)$$

Con $m = \alpha$ o β .

A estas funciones se les puede aplicar DWT y MM, para efectuar una comparación entre las señales progresivas y las regresivas en el primer instante de ocurrida la falta.

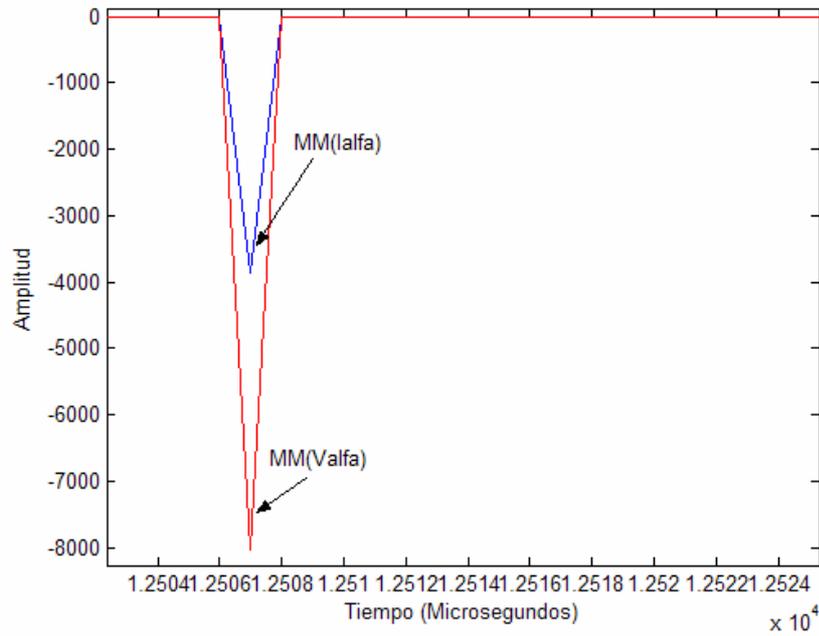
El criterio, pudiera ser en función de que cada una de las funciones (4.5.7) y (4.5.8) resaltan las componentes progresivas y regresivas. Así que la relación entre ellas, sirve para establecer la direccionalidad.

Este tema no ha sido totalmente cubierto ni en el presente trabajo ni en la literatura revisada. Así que se recomienda para un futuro trabajo de investigación ligado al área de localización o de protecciones eléctricas.

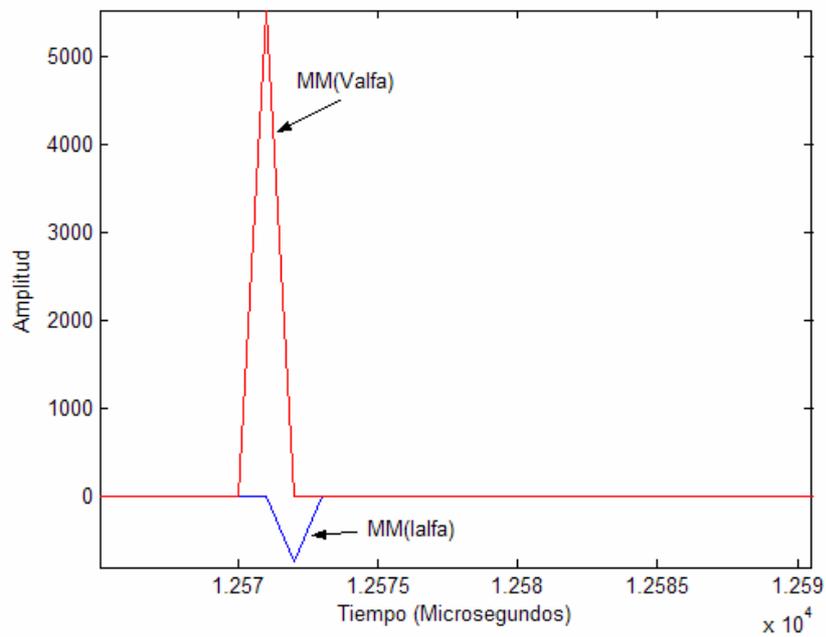
Para el presente trabajo, la metodología utilizada corresponde a la del primer planteamiento, pero trabajando con las componentes de alta frecuencia obtenidas de sus coeficientes por la descomposición de wavelets. La transformada a utilizar puede ser indistintamente la continua compleja o la discreta.

Como ejemplo de la metodología planteada, se presenta en la Fig. 4-40, la comparación entre las señales del MM de la tensión y corriente modal, para una falta en sentido directo (hacia delante) y una falta en sentido inverso (externa). Este procedimiento ha demostrado ser confiable tanto para bajos ángulos de inserción como para altas impedancias de falta.

El diagrama de flujo para establecer la dirección de la falta detectada y clasificada, viene establecido en la Fig. 4-41.



(a)



(b)

Fig. 4-40. Determinación de Direccionalidad por Polaridad del primer pico del MM de las señales de tensión y corriente modal. (a) Falta Externa, (b) Falta interna.

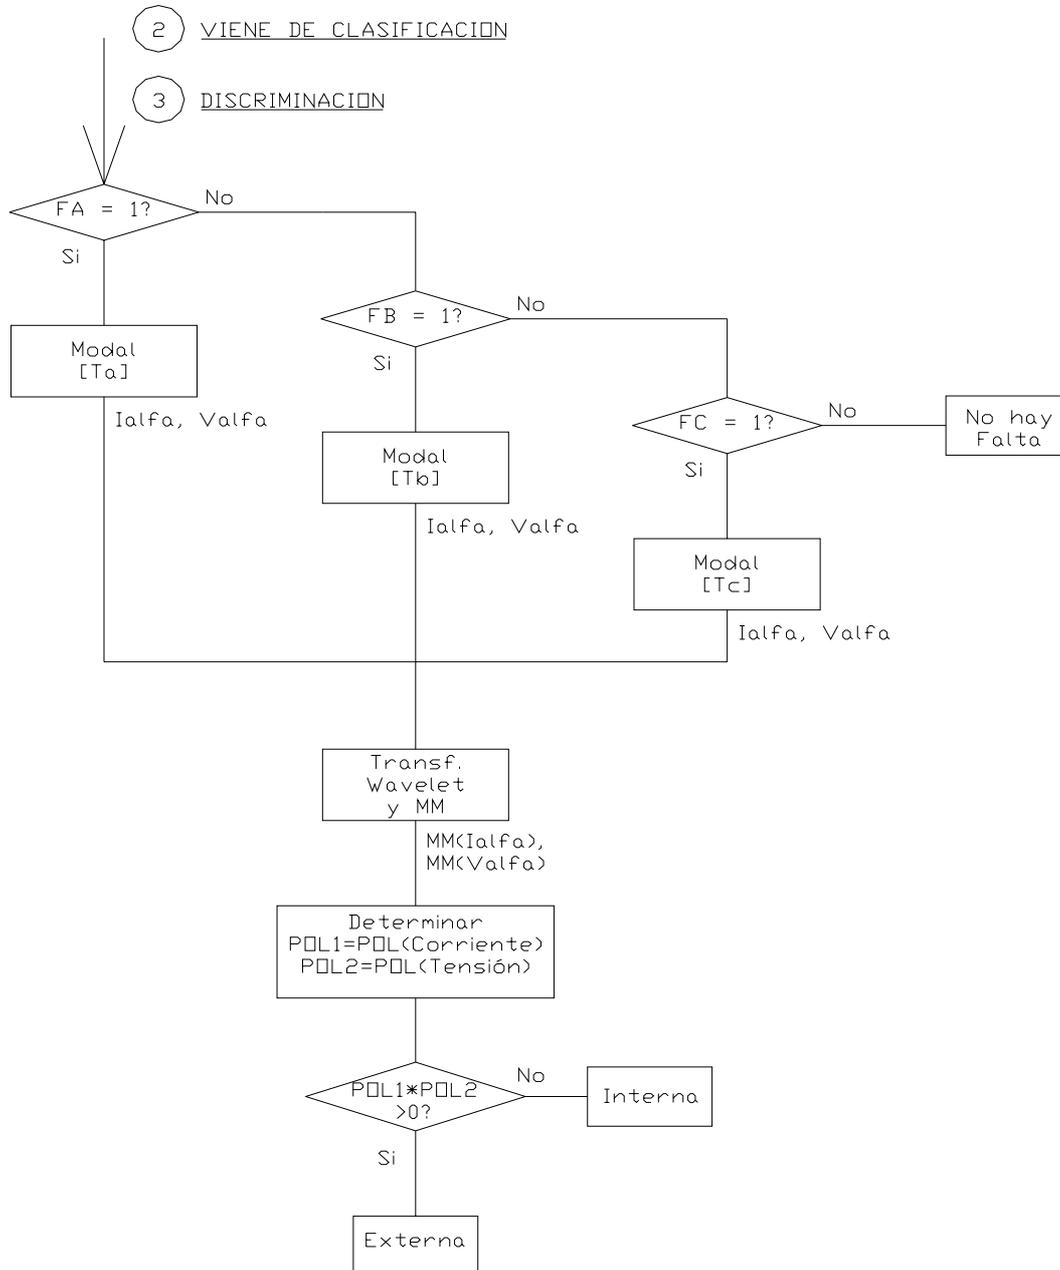


Fig. 4-41. Algoritmo para la discriminación de la falta (Interna – Externa).



4.6.- Algoritmo para la Localización de la falta:

La localización de la falta (en caso de ser interna), puede llevarse a cabo de diversas maneras. Tal como se indicó en el apartado de la revisión bibliográfica, existen muchos métodos para la localización de la falta y su interés radica precisamente en la velocidad y precisión del cálculo.

El objetivo inicial de este trabajo, radicaba en la revisión de [90], donde D. Zhang, et al, plantean un método para la localización de faltas en sistemas de transmisión para su uso en algoritmos de protección. Por ello, definen al esquema como protección “Posicional”, pues el algoritmo a diferencia de un relé de distancia, busca con mayor exactitud la posición (o localización) de la falta para dar la orden de disparo del interruptor. Como técnica se utiliza la transformada Wavelet, continua compleja y con sus componentes de alta frecuencia ubicar los distintos rebotes de la onda viajera.

Sin embargo, tras la revisión efectuada, se encontraron otros métodos que se unieron a las alternativas, ya que eran aplicables a partir de la transformada wavelet.

a.- A partir de la obtención de los fasores de tensión y corriente:

a.1.- Con medición en ambos extremos:

En función del uso que se le ha dado a los fasores calculados o estimados a lo largo de las tareas de detección y clasificación, se justifica también la estimación de la distancia a la falta (localización) con esta metodología.

Así que la distancia se estima como el promedio de los factores modales expuestos en la siguiente ecuación:



$$D_m := \frac{\ln\left(\frac{N_m}{M_m}\right)}{2 \cdot \Gamma_m \cdot L} \quad \text{con } m = \alpha, \beta, 0. \quad (4.6.1)$$

$$D_f := \frac{\sum_{m=\alpha}^0 D_m}{3} \quad (4.6.2)$$

Donde :

L, es la longitud total de la línea,

Γ es la constante de propagación,

$$N_m = \frac{1}{2} [V_{r_m} - Z_{0_m} \cdot I_{r_m}] - \frac{1}{2} e^{\Gamma_m L} [V_{s_m} - Z_{0_m} \cdot I_{s_m}] \quad (4.6.3)$$

$$M_m = \frac{1}{2} e^{-\Gamma_m L} [V_{s_m} + Z_{0_m} \cdot I_{s_m}] - \frac{1}{2} [V_{r_m} + Z_{0_m} \cdot I_{r_m}] \quad (4.6.4)$$

V_r e I_r , V_s e I_s , son las tensiones y corrientes de los lados R y S, respectivamente.

Con esta propuesta, según [74], se logran errores inferiores al 1%.

a.2.- Con la medición en un solo extremo:

Esta es la técnica más utilizada, pues se basa en el cálculo de la impedancia eléctrica de la línea en fallo, mediante la relación entre los fasores de tensión y corriente. La localización de la falta, se efectúa entonces, estimando la distancia a partir de una relación lineal de la impedancia con la longitud de la línea.

Este método es empleado por la mayoría de los localizadores de fallos y por los relés de distancia. Lo que se añadiría es la forma de obtener los fasores, pues, en vez de utilizar Fourier para el filtrado y posterior obtención de la señal a frecuencia fundamental, se utilizaría Wavelets, con los procedimientos que ya han sido descritos con anterioridad.



Luego, según el tipo de falta, puede estimarse la impedancia, según la siguiente relación:

- Para faltas monofásicas:

$$Z_{\phi} := \frac{V_{\phi}}{I_{\phi p} + I_{\phi n} + K_o \cdot I_{\phi 0}} \quad (4.6.5)$$

Donde:

La terminología p, n y o, corresponde a las cantidades en secuencias directa, inversa y homopolar, respectivamente.

$$K_o := \frac{Z_{L_o}}{Z_{L_p}} \quad (4.6.6)$$

Z_{L_o} es la impedancia de la línea en secuencia homopolar

Z_{L_p} es la impedancia de la línea en secuencia directa

Y para faltas bifásicas entre la fase ϕ_1 y la ϕ_2 :

$$Z_{\phi_1 - \phi_2} := \frac{V_{\phi_1} - V_{\phi_2}}{I_{\phi_1} - I_{\phi_2}} \quad (4.6.7)$$

Y así para el resto.

Existen varios trabajos [53, 102], que indican que utilizando la transformada wavelet (discreta) para la estimación fasorial y con ventanas adaptivas al momento de detección del evento, se pueden lograr reducir sensiblemente los tiempos de actuación de las protecciones, pues se logra estimar de una forma más rápida la impedancia vista por el relé.

En las Fig. 4-42 y 4-43, se observan los resultados obtenidos en [53], los cuales fueron verificados tras la programación de la metodología en Matlab. En la primera, se obtiene la variación del módulo de la impedancia con el tiempo, tras ocurrir una falta

bifásica (AC) a tierra y en el segundo se muestra la trayectoria de dicha impedancia en el plano complejo (R-X).

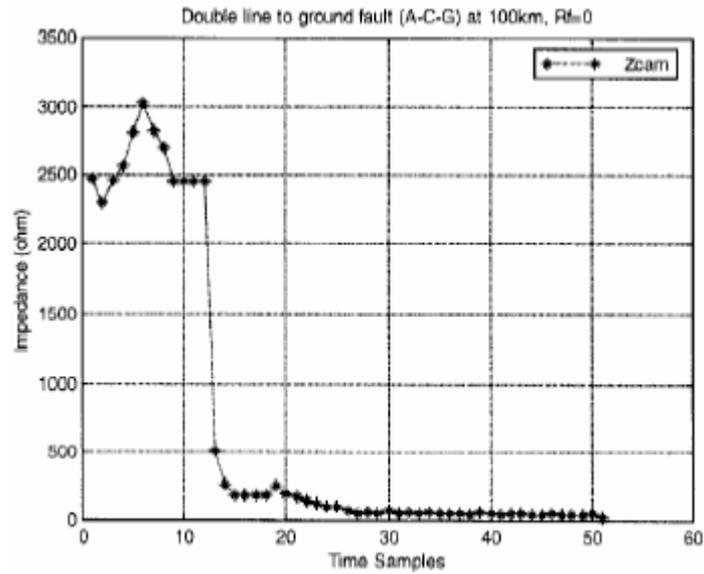


Fig. 4-42. Variación de Z_f vs t , para una falta FACT.

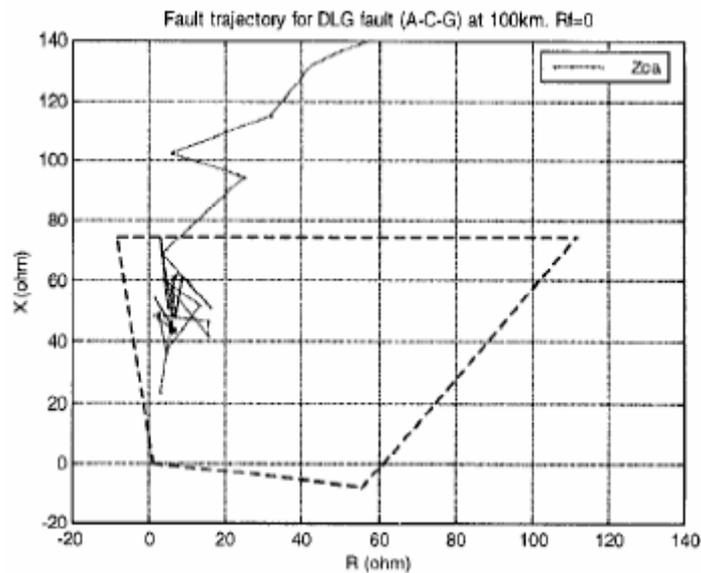


Fig. 4-43. Trayectoria en el plano R-X de la falta FACT.

b.- Utilizando las señales de alta frecuencia (onda viajera):

Si se tienen las ondas transitorias registradas, puede obtenerse a través del equivalente de tiempos de viaje, la posición del evento que originó un cambio en el medio de propagación (falta)

Haciendo un diagrama de Laticce, como el mostrado en la Fig. 4-44, se pueden establecer de forma teórica las señales que incidirán sobre los extremos de la línea, así como sus respectivas polaridades (diagrama realizado en base a señales de voltaje). También el efecto de las ondas reflejadas y sus polaridades debe ser estudiado con detalle, para poder diferenciar de forma adecuada a cada uno de dichos eventos.

Para ello, se trabajan con las señales de tensión, ya que las corrientes no dan información útil a este respecto. Adicionalmente, en sistemas trifásicos, es necesario trabajar en el dominio modal, para tener desacoplados los modos aéreos y de tierra, ya que ambos tienen velocidades de propagación distintas.

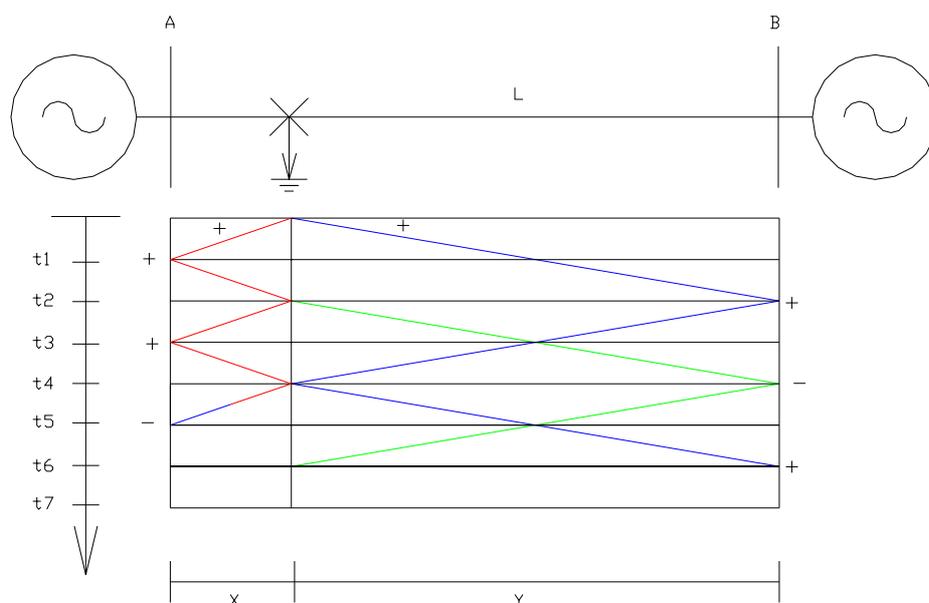


Fig. 4-44. Diagrama de Laticce de un sistema bajo falta.

En función de dicho diagrama, se pueden obtener las ondas incidentes registradas en los nudos A y B, como se muestra en la Fig. 4-45 (representadas por simplificación como funciones impulsivas – tipo delta de dirac).

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:

$$X := \frac{v \cdot (t_3 - t_1)}{2} \quad (4.6.8)$$

$$Y := \frac{v \cdot (t_6 - t_2)}{2} \quad (4.6.9)$$

Donde:

v es la velocidad de propagación de la onda electromagnética para el modo m, utilizado (α , β ó 0).

(t_3-t_1) ó (t_6-t_2): intervalo de tiempo entre la llegada de dos señales de polaridad positiva.

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 precisa de la incidencia de cada señal.

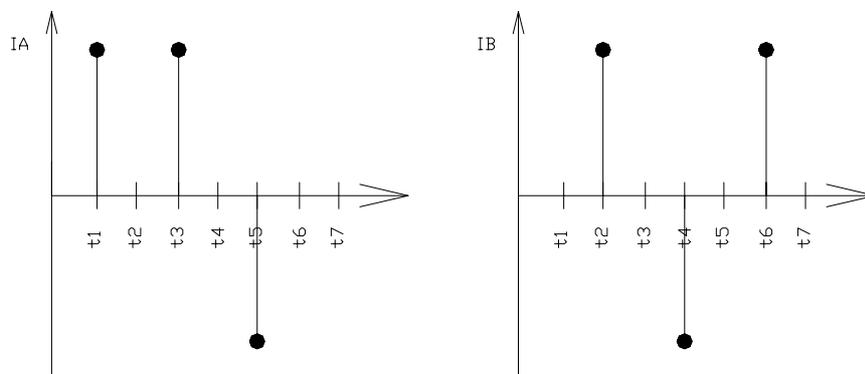


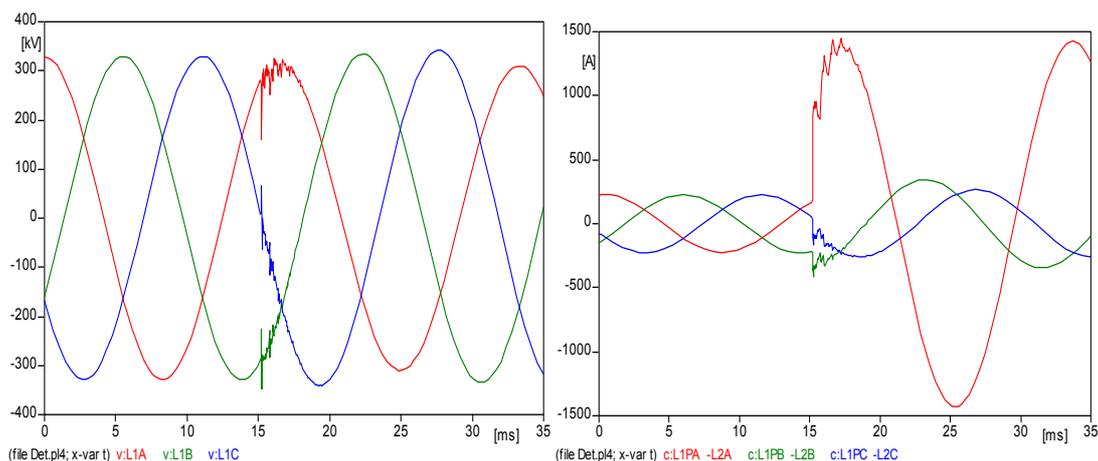
Fig. 4-45. Esquema reducido de las señales registradas en los nudos A y B (con sus respectivas polaridades).

Una de las formas propuesta en la literatura para resolver este aspecto, se basa en la aplicación de la transformada wavelet para la obtención de las componentes de alta frecuencia y su posterior postprocesamiento o limpieza, mediante diversas técnicas como:

- Modulus Maxima (MM)
- Información Combinada (IC)
- Ambos (MM+IC), tal como ya ha sido descrito en detalle con anterioridad.

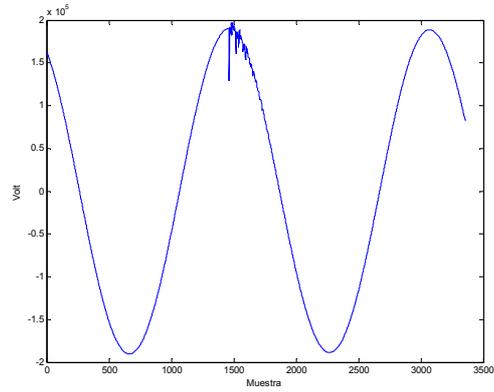
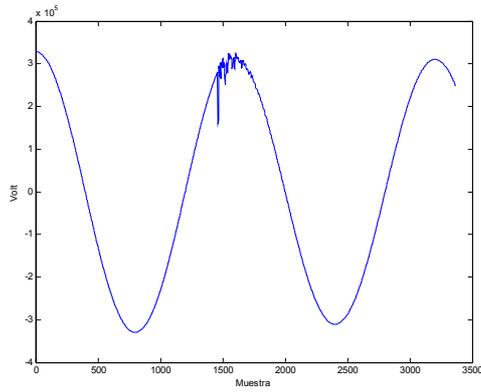
Este procedimiento tiene como fuente de error, el retraso real entre la incidencia de la onda y el instante del MM (este puede llegar a ser del orden de $8 \mu\text{s}$ [98]).

Planteando un ejemplo con un sistema sencillo de dos barras como el mostrado para el análisis en la Fig. 4-44, con una falta 1ϕ (Fase A), a 80 Km de A, se obtienen los gráficos mostrados en la Fig. 4-46.

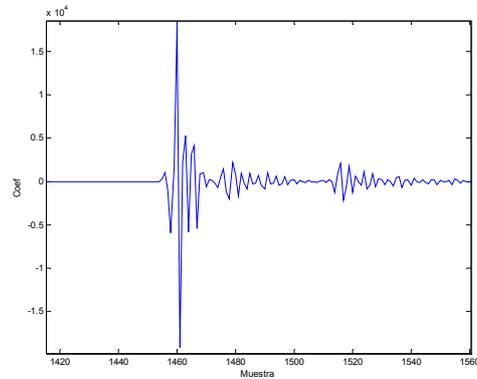
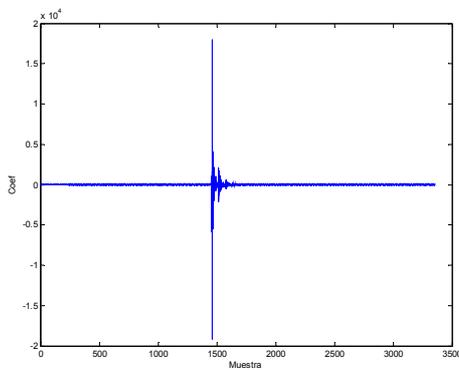


(a) Voltajes por fase en nodo A

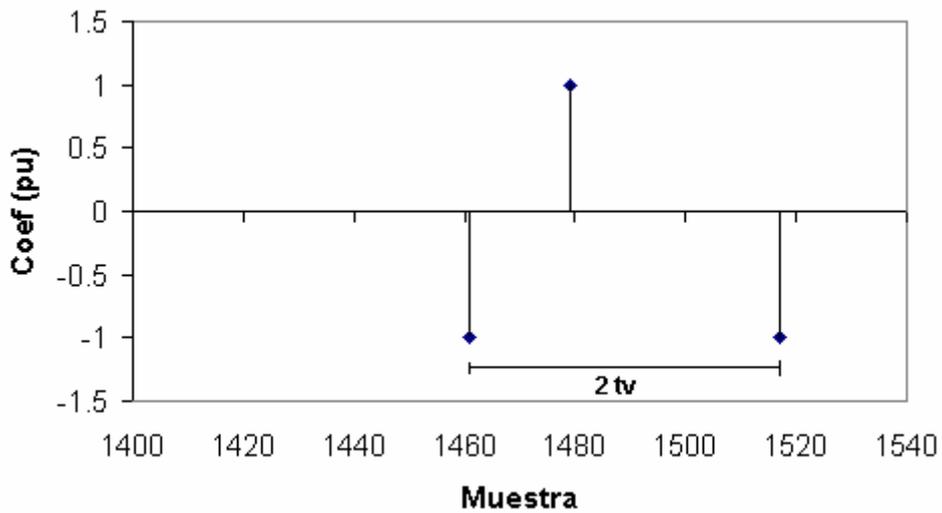
(b) Corrientes por fase nodos (A-B)



(c) detalle del Voltaje en la Fase A – nodo(A). (d) Voltaje modal (α) – en nodo (A)



(e) Coeficientes de la DWT db4-d1 (f) Detalle ampliado de (e)



(g) MM de la señal mostrada en (f).

Fig. 4-46. Localización de faltas, utilizando TW.



Según se indica en la Fig.4-46 (g), la cantidad de muestras que distancian los dos picos de polaridad negativa, son: 53.

La distancia entre muestras, tiene un ΔT (@ 96000 Hz) de 10.4 μs .

Eso implica, que la separación entre dichas señales es: 551.2 μs .

Y corresponde a dos veces el tiempo de viaje, por lo que

$$T_v = 551.2/2 = 275.6 \mu s.$$

A una velocidad de propagación de $v_\alpha = 296 \text{ m}/\mu s$.

Por lo que la distancia es: **81.6 Km** (error = 2%).

El gran dilema en torno a estas técnicas es cómo medir las tensiones en este rango de frecuencia. El equipamiento (divisores capacitivos) tiene grandes restricciones, por lo que la herramienta necesita adecuarse a la realidad, especialmente ante faltas muy cercanas a la barra de medición. Adicionalmente, la gran desventaja de trabajar con esta información es que ante bajos ángulos de inserción, no se generan ondas viajeras o son de muy pequeña magnitud como para que sea factible su análisis con estas técnicas.

Adicionalmente, se observó la ventaja de variar la matriz de transformación modal según, las fases involucradas, ya que las ondas obtenidas para cualquier tipo de falta bajo este esquema, arrojaban patrones idénticos, lo que facilita enormemente su aplicación algorítmica dentro de algún esquema automatizado o de inteligencia artificial como una red neuronal.

La asignación o uso de la matriz de transformación, según el tipo de falta, se hizo siguiendo lo establecido en la siguiente tabla resumen (tabla III).



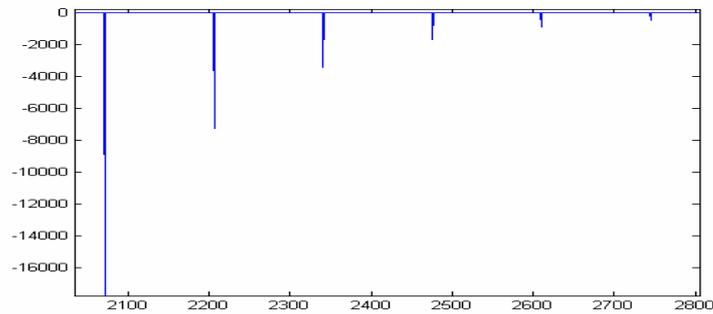
Tabla III. Referencia de fase para la obtención de la matriz de transformación modal, según el tipo de falta.

Tipo de Falta	Matriz T, respecto a fase
FAT	A
FBT	B
FCT	C
FABT	A
FBCT	B
FCAT	A
FAB	A
FBC	B
FCA	C
FABC	A

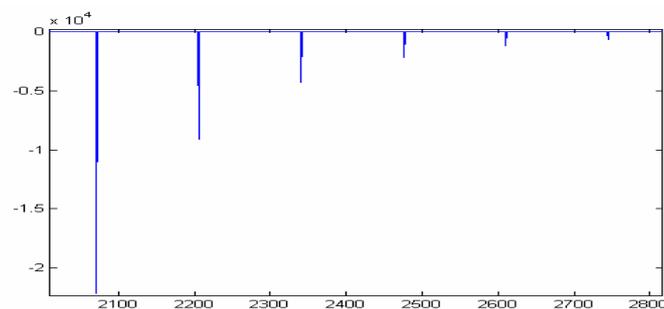
Un ejemplo, sencillo, se muestra en la Fig. 4-47.

Esa información va a ser utilizada para la siguiente etapa que es la creación de una red neuronal que se encargue de procesar la data y arrojar la localización de la falta.

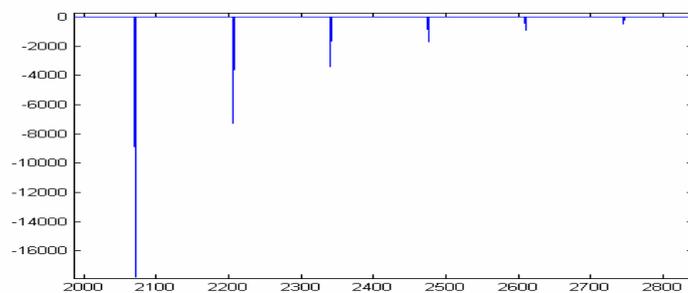
Como ha sido mencionado en el capítulo anterior, la red neuronal seleccionada para este fin es la que utiliza una función de base radial para el ajuste de las funciones de peso.



(a) FABC (Ta)



(b) FBCT (Tb)



(c) FAB (Ta)

Fig. 4-47. MM de las señales de tensión del modo α , para distintos tipos de faltas y variando la matriz, respecto a lo indicado en la tabla III.

Como datos de entrada para esta red de localización, se han establecido los siete (7) primeros picos del MM de la señal de tensión, para el modo α .

Pero tomando en cuenta que los datos importantes son: posición y polaridad, se desecha la magnitud del pico y se realiza la siguiente referencia.

Sea V_p , el vector que contiene los siete (7) primeros picos del MM de la TW de la señal V_α , medida en una de las barras del sistema.

$$V_p = [V_{p1}(x_1), V_{p2}(x_2), V_{p3}(x_3), V_{p4}(x_4), V_{p5}(x_5), V_{p6}(x_6), V_{p7}(x_7)] \quad (4.6.10)$$

Donde x_n es la posición del pico en veces el paso de muestreo ΔT .

Si llamamos P_n a la polaridad o signo de V_{Pn} y fijamos como referencia de posición a x_1 , el vector de interés para la localización, corresponderá a:

$$V_L = [P_1*1, P_2*(x_2-x_1), P_3*(x_3-x_1), \dots, P_n*(x_n-x_1)] \quad (4.6.11)$$

Los casos seleccionados para el entrenamiento de la red neuronal deberán contener esta información como data de entrada y como salida prefijada, la distancia de la falta.

Así, el vector de salida corresponderá para cada caso:

$$V_{salida} = [Df] \text{ en Km} \quad (4.6.12)$$

Un ejemplo de los archivos de entrenamiento, se muestra en la Fig. 4-48.

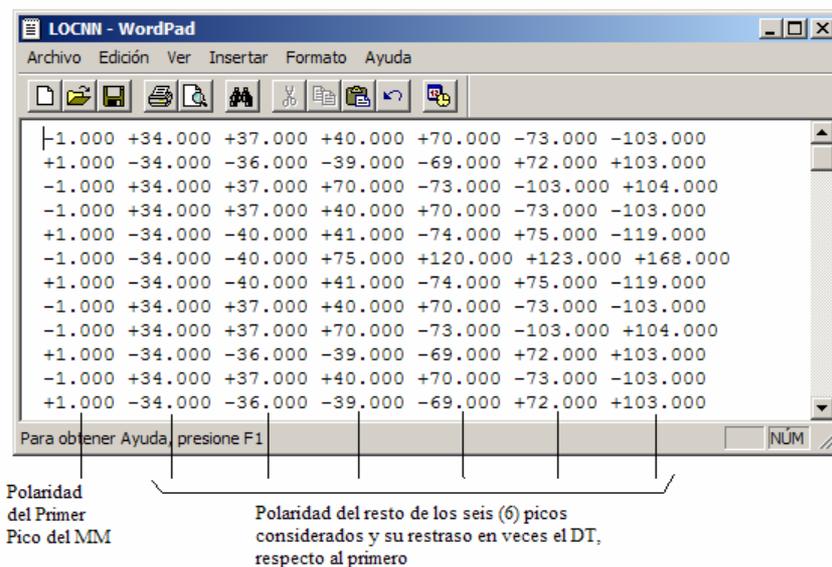


Fig. 4-48. Archivo con la información del Vector V_L .



La razón de colocar los siete primeros picos y no otra cantidad es para asegurar que se posee la suficiente información para una correcta y rápida localización de la falta.

La red, posee tres capas: la primera la correspondiente al vector de entrada y por lo tanto contiene siete neuronas; la segunda es la de ajuste de pesos y posee 10 neuronas, este número fue extraído empíricamente al probar con cuántas neuronas se tenía buenos resultados en cuanto a la generalización del modelo. Y la tercera posee una sola neurona de salida que corresponde a la localización de la falta en referencia al punto de medición.

Al igual que en el caso de clasificación, la red neuronal fue creada, entrenada y simulada, utilizando el menú de “nntools” de las herramientas de redes neuronales (“Neural Network Toolboxes”) de Matlab en su versión 6.5.

También se probó la red del tipo BP (retropropagación), encontrándose igualmente resultados satisfactorios.

Se recomienda hacer en un trabajo futuro una mayor indagación sobre las ventajas de ambos tipos de redes para aplicaciones en tiempo real, basándose en sus aplicaciones en “hardware”.

El Algoritmo implementado para la localización de las faltas, puede resumirse en el siguiente diagrama de Flujos (Fig. 4-49).

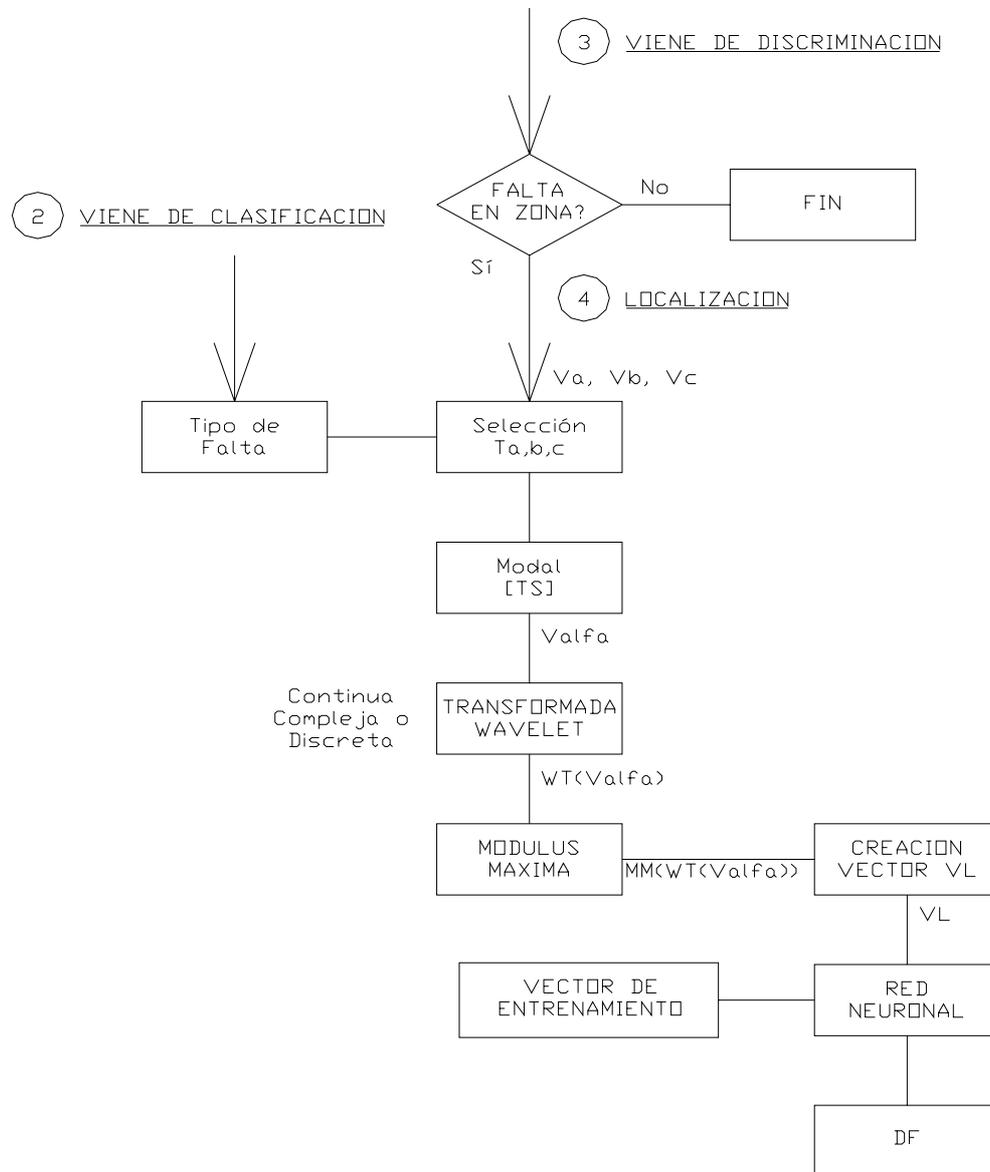


Fig. 4-49. Algoritmo para la Localización de la falta, utilizando redes neuronales.

El entrenamiento de la red con función base radial, se realizó siguiendo el mismo esquema presentado en el algoritmo de clasificación (Fig. 4-37), utilizando la variación sistemática de los factores de interés (ángulo de inserción, impedancia de falta, tipo de falta y localización en la línea), mediante la simulación en el programa de transitorios electromagnéticos EMTP/ATP, a través de una interfaz con Matlab, vía controlex “ActiveX”.



c.- Utilizando las señales de alta frecuencia de corriente:

También se ha querido hacer referencia por lo llamativo y diferente, al único trabajo que utiliza la transformada Wavelet sobre las señales de corriente, para la localización de faltas [118]. Para ello, plantea un algoritmo que utiliza la información de la clasificación de la falta (obligatoria) para estimar una función denominada S_p y que agrupa la sumatoria de los coeficientes pertenecientes al tercer detalle de la función db8, tomando en cuenta las corrientes de las fases involucradas en la falta.

Así, puede definirse:

$$S_{\phi} := \sum_{k=1}^N I_{3\phi}(k) \tag{4.6.13}$$

Donde:

ϕ : A, B, C.

N: número de muestras en la ventana considerada.

$I_{3\phi}$: db8-d3 de la $I_{\phi}(t)$

Y :

$$S_p := \sum_{\phi f} S_{\phi} \tag{4.6.14}$$

Donde :

ϕf : son las fases involucradas en la falta (según clasificación previa)

Por ejemplo, para una falta bifásica FA-B, el término $S_p = S_a + S_b$ y así para cualquier otro caso.



El algoritmo utiliza una base de datos previamente creada, en la que se tiene almacenado un grupo de valores de S_p a distintas localizaciones.

Luego de calculado el S_p de la falta, se hace una búsqueda de los S_p más cercanos (por encima y por debajo) en la base de datos y por último mediante una interpolación cúbica estima el valor de la distancia a la falta.

Como se observa, este tipo de procedimientos son similares a los basados en inteligencia artificial, pero en este caso la función de ajuste es variable ya que se basa en la interpolación y no en el ajuste.

Los errores obtenidos en las pruebas realizadas, son inferiores al 0.3%.

d.- Utilizando el comportamiento del perfil de tensiones a lo largo de la línea:

Una de las metodologías más recientemente desarrolladas para la localización de faltas con la información de tensiones y corrientes de un solo extremo de la línea, se presenta en [132 y 133].

Si bien el algoritmo planteado en este trabajo es el descrito en el punto b, las metodologías que solo utilizan la información transitoria (onda viajera), tienen la gran desventaja de no detectar o ubicar faltas bajo las siguientes condiciones:

- Muy cercanas a la barra de medición, pues ocurre una superposición de las componentes de los distintos rebotes.
- Bajos ángulos de inserción de falta, pues las magnitudes de los picos del MM, son prácticamente cero y se podrían confundir fácilmente con fuentes de ruido existente a la misma frecuencia.



Por todo lo anterior, se hace indispensable plantear metodologías (tanto para protección como para localización) que no dependan únicamente de la información de alta frecuencia, ni tampoco de la información a la frecuencia fundamental (pues ésta última también tiene ciertas dificultades como por ejemplo su alta dependencia con el valor de la impedancia de falta).

Esta metodología, utiliza ambas informaciones (al igual que este hecho fue aprovechado en el algoritmo de clasificación de faltas), basándose en el comportamiento de la distribución de las tensiones de fase a lo largo de la línea en fallo.

La base de la metodología es el modelo de línea de parámetros distribuidos, utilizando las ecuaciones del telégrafo. Lo que [132 y 133] demuestran es que a partir de dichas ecuaciones puede derivarse un perfil de tensiones ficticio (pues no se toma en cuenta la condición de borde de la falta), cuya norma en tiempo y fase, posee un mínimo global en el punto de falta.

A continuación se van a desarrollar las ecuaciones para llegar al planteamiento y aplicar la transformada wavelets a las tensiones y corrientes, para obtener una función que contenga lo más significativo en cuanto a información de baja y alta frecuencia.

Cabe indicar que de una vez se va a partir del hecho de que se tiene una línea de transmisión trifásica (balanceada o no) y que si bien la información para localización debe ser en el dominio de las fases, su obtención se va a desarrollar en el dominio modal.

Así que las ecuaciones del telégrafo en el dominio de la frecuencia y con la información de tensiones y corrientes modales, podrían ser escritas como:

$$-\frac{dU_m x}{dx} = (R_m + j\omega L_m) \cdot I_m x \quad (4.6.15)$$



$$-\frac{dI_m x}{dx} = (G_m + j\omega C_m) \cdot U_m x \quad (4.6.16)$$

Donde:

$m = a, b, 0$.

R_m , L_m , G_m y C_m , son los parámetros de la línea en el dominio modal y por unidad de longitud.

Si la tensión y corriente es conocida en el extremo de medición ($x=0$), entonces la solución a las ecuaciones anteriores en el dominio de la frecuencia, es:

$$U_m x = \frac{1}{2} \left[e^{-\gamma x} (U_m^o + Z_m^o I_m^o) + e^{\gamma x} (U_m^o - Z_m^o I_m^o) \right] \quad (4.6.17)$$

$$I_m x = \frac{1}{2Z_m^o} \left[e^{-\gamma x} (U_m^o + Z_m^o I_m^o) - e^{\gamma x} (U_m^o - Z_m^o I_m^o) \right] \quad (4.6.18)$$

Donde:

γ : es la constante de propagación,

Z_m^o : es la impedancia de onda

U_m^o e I_m^o , son la tensión y corriente en $x=0$, respectivamente.

Con:

$$\gamma = \sqrt{(R_m + j\omega L_m)(G_m + j\omega C_m)} \quad (4.6.19)$$

$$Z_m^o = \sqrt{\frac{(R_m + j\omega L_m)}{(G_m + j\omega C_m)}} \quad (4.6.20)$$

Si se definen, para cada solución, los siguientes términos como componentes progresivos (F) y regresivos (B):

$$F_m^o = U_m^o + Z_m^o I_m^o \quad (4.6.21)$$

$$B_m^o = U_m^o - Z_m^o I_m^o \quad (4.6.22)$$



Y se podría reescribir la ecuación (4.6.17), como se muestra a continuación:

$$U_m x = \frac{1}{2} \left[e^{-\gamma x} \cdot F_m^o + e^{\gamma x} \cdot B_m^o \right] \quad (4.6.23)$$

Y tal como ha sido explicado al inicio de este capítulo, la representación en el dominio del tiempo, quedaría de la siguiente manera:

$$u_m(x, t) = \frac{1}{2} \left[e^{-\alpha x} \cdot f_m^o \left(t - \frac{x}{v} \right) + e^{\alpha x} \cdot b_m^o \left(t + \frac{x}{v} \right) \right] \quad (4.6.24)$$

Donde:

v : es la velocidad de propagación para el modo considerado.

$$\alpha = (R_m / Z_m^o) \quad (4.6.25)$$

Una vez obtenida la expresión general para la obtención del perfil de tensiones de la línea en el dominio modal, hay que transformarlo al dominio de las fases, utilizando la matriz de transformación de Karrenbauer.

$$\left[u_\phi \right] = [Tm] \left[u_m \right] \quad (4.6.26)$$

Y se define:

$$Ad_\phi(x) = \left| u_\phi(x, t) \right|_t \quad (4.6.27)$$

Donde:

$$\left| u_\phi(x, t) \right|_t = \sum_t abs(u_\phi(x, t)) \quad (4.6.28)$$



Como ya fue mencionado anteriormente, el perfil de tensiones que se obtendría siguiendo este procedimiento es ficticio, pues no toma en cuenta la variación de la corriente como condición de borde en el punto de falta. Por ello, el perfil sería válido hasta el punto de falta y no válido en adelante. Sin embargo, el objetivo no es obtener las tensiones a lo largo de la línea, sino la localización de la falta.

La programación de estas ecuaciones es bastante sencilla, pero requiere de un tiempo relativamente alto de cómputo pues necesita evaluar la expresión de A_d , para una de las fases falladas (no es necesario evaluar más que una, de las fases que ha sido previamente identificada con el algoritmo de clasificación), en función de la distancia (desde $x = 0$, hasta $x = L$, donde L es la longitud de la línea de interés).

El otro factor importante es conocer la tensión y corriente (U_m^o e I_m^o), con los que se va a trabajar. Al incorporar la TW en la formulación y tomar en cuenta parámetros tanto de alta como de baja frecuencia, lo que se plantea es:

- Tomar los coeficientes del detalle (d) uno de la DWT db4 de cada señal
- Tomar los coeficientes de la aproximación (a) de la DWT en el nivel 12 (tomando en cuenta una frecuencia de muestreo de 1 MHz).

Así:

$$U_m^o(t) = (d^1(t) + a^{12}(t)) \quad (4.6.29)$$

Y de la misma forma para la corriente.

Un ejemplo de los resultados que se obtendrían al evaluar el coeficiente A_d , según ha sido descrito todo el procedimiento anteriormente, ante una falta monofásica a tierra en la fase A y variando la ubicación de la falta en (5, 15, 25 y 35 Km), se muestra en la siguiente figura.

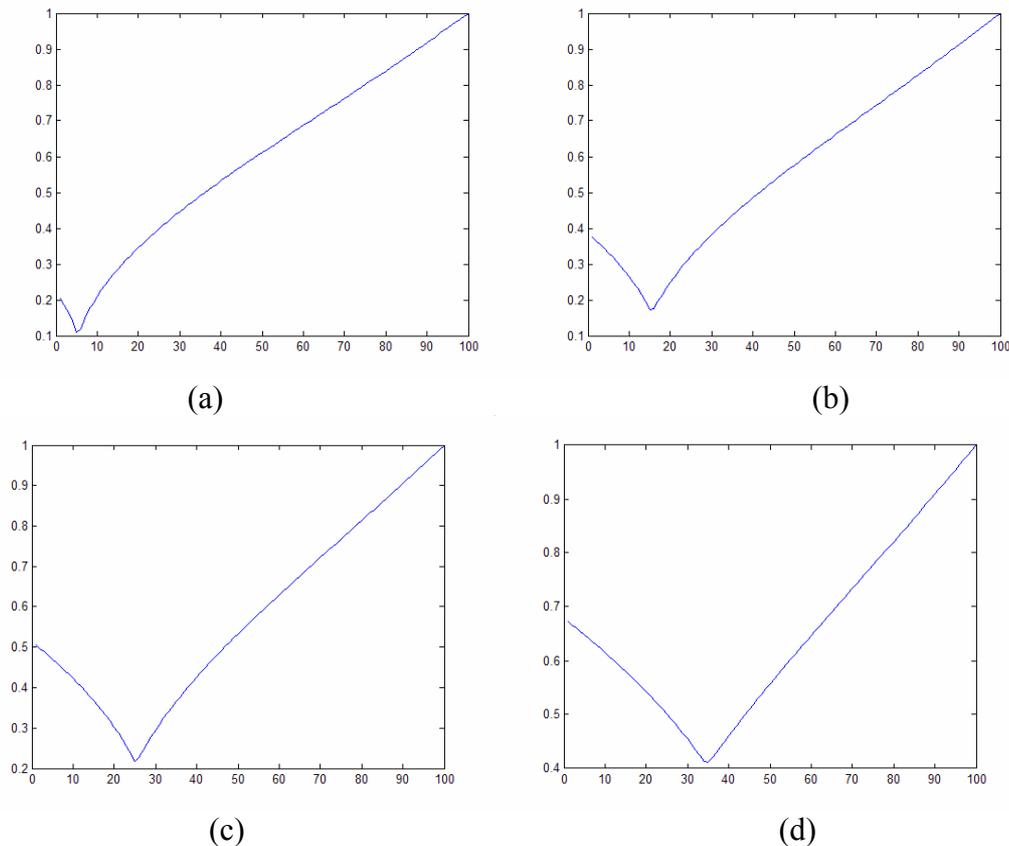


Fig. 4-50. Evaluación del parámetro A_d (abscisa) a lo largo de la longitud de la línea (coordenada) de 100 Km, para una falta FAT en (a) 5 Km, (b) 15 Km, (c) 25 Km y (d) 35 Km.

Una acotación importante que puede ser tomada en cuenta para realizar variaciones en la metodología propuesta para aplicarla en tiempo real o al menos reducir la cantidad de cómputo necesario, es que partiendo desde ambos extremos, el comportamiento del perfil es prácticamente lineal y además:

Si $D_f < 50\% L$, entonces $A_d(x=0) < A_d(x=L)$

Si $D_f > 50\% L$, entonces $A_d(x=0) > A_d(x=L)$

Estos datos son fácilmente implementables en una red neuronal para la ubicación de la falta. Sin embargo, se deja este desarrollo para trabajos futuros en el área.

5.- APLICACIÓN A UN CASO PRÁCTICO:

5.1.- Introducción



A continuación se presenta un capítulo práctico, en el cual los algoritmos de detección, clasificación, discriminación direccional y localización descritos en el capítulo anterior, serán aplicados a un caso didáctico, compuesto por tres líneas de transmisión y dos generadores.

Lo primero será describir los detalles técnicos del sistema de interés, para posteriormente plantear los escenarios de falta que serán estudiados. Luego se describirán los modelos seleccionados para la incorporación del sistema en el programa de transitorios electromagnéticos EMTP/ATP y por último se colocarán los resultados obtenidos para cada una de las tareas desarrolladas.

5.2.- Descripción Del Sistema

Como ya ha sido mencionado, el sistema consta de cuatro (4) barras, compuesto por tres líneas de transporte, dos generadores y una carga.

a.- Datos de los componentes:

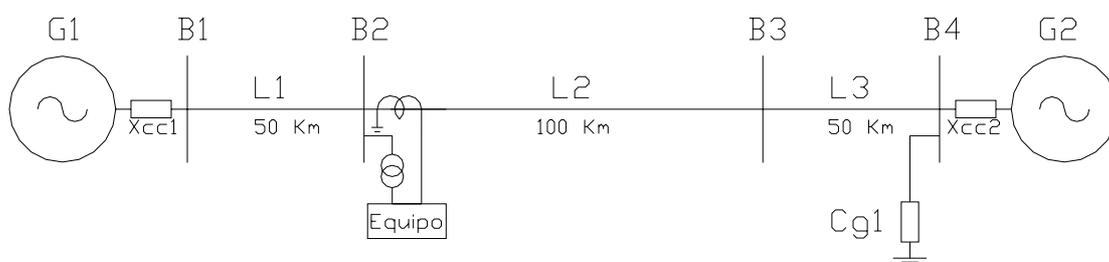


Fig.5-1. Sistema en Estudio

Los datos del sistema, son los siguientes:

Tensión nominal (V_n) = 400 kV

frecuencia = 50 Hz

Datos Operación Generadores:

$E_{intg1} = 1.01 \angle 1^\circ$ pu

$E_{intg2} = 0.97 \angle 0^\circ$ pu

Equivalente de Cortocircuito :

$L_{cc1^+} = 2.5$ mH

$L_{cc1^0} = 1.5$ mH

$L_{cc2^+} = 25$ mH

$L_{cc2^0} = 15$ mH

Líneas de Transmisión:

El esquema geométrico de la línea viene definido por la Fig. 5-2.

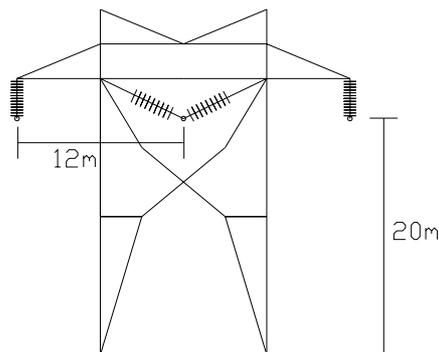


Fig. 5-2. Geometría de la línea de Transporte.

Los datos de los conductores, son:

$R_{DC \text{ cond}} = 0.0531 \Omega/\text{Km}$.

$\Phi_{\text{cond}} = 2.923$ cm.

$\rho = 100 \Omega\text{-m}$



Transformadores de medida (corriente):

$$TC = 1000/5 \text{ A.}$$

$$L_p = 1 \times 10^{-7} \text{ mH}$$

$$R_s = 0.1 \ \Omega.$$

Se consideró el núcleo saturable del TC y la característica no lineal utilizada, está indicada en la Tabla IV.

Tabla IV. Característica no lineal del TC.

I (A)	Flujo (V-s)
0.1	0.45
0.13	0.67
0.45	1.48
1.35	1.80
81.61	4.17

Carga (Cg1):

$$R_{cg1} = 500 \ \Omega.$$

$$L_{cg1} = 10 \text{ mH.}$$

Frecuencia de muestreo:

Se tomó una frecuencia de muestreo de 1 MHz (frecuencia del sistema = 50 Hz, 20000 muestras por ciclo). Y la evaluación de todos los escenarios y tareas, se realizó con una ventana móvil de $\frac{1}{2}$ ciclo de longitud (10000 muestras).



b.- Escenarios a estudiar:

- Tipos de falta:

Se consideraron los cuatro tipo de faltas transversales, los cuales generan diez posibles faltas en el sistema :

F3 ϕ

b.1.- FABC

F2 ϕ -T

b.2.- FABT

b.3.- FBCT

b.4.- FCAT

F2 ϕ

b.5.- FAB

b.6.- FBC

b.7.- FCA

F1 ϕ

b.8.- FAT

b.9.- FBT

b.10.- FCT

- Localización de las faltas:

Se tomaron dos posibilidades (Fig. 5-3):

Externas:

En barras (B2 y B3)

Internas:

Tres Internas localizadas al inicio, mitad y final de la línea B2-B3 (0%, 50% y 100% de la longitud de la línea B2-B3).

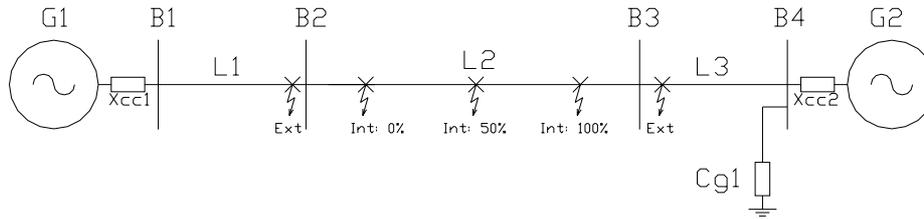


Fig. 5-3. Escenarios de Falta a utilizar

- *Impedancia de Falta:*

Se tomaron tres posibles condiciones de impedancia de falta: 0Ω , 10Ω y 30Ω .

El valor mayor, fue seleccionado de los típicos considerados para este tipo de aplicaciones en Red Eléctrica de España.

- *Angulo de inserción de la falta:*

Como se muestra en la siguiente Fig. 5-4, se va a relacionar con el tiempo de actuación (cierre) del o de los interruptores de simulación de falta.

En la Tabla V, se indican dichos tiempos y en ángulo su valor respecto a la fase A.

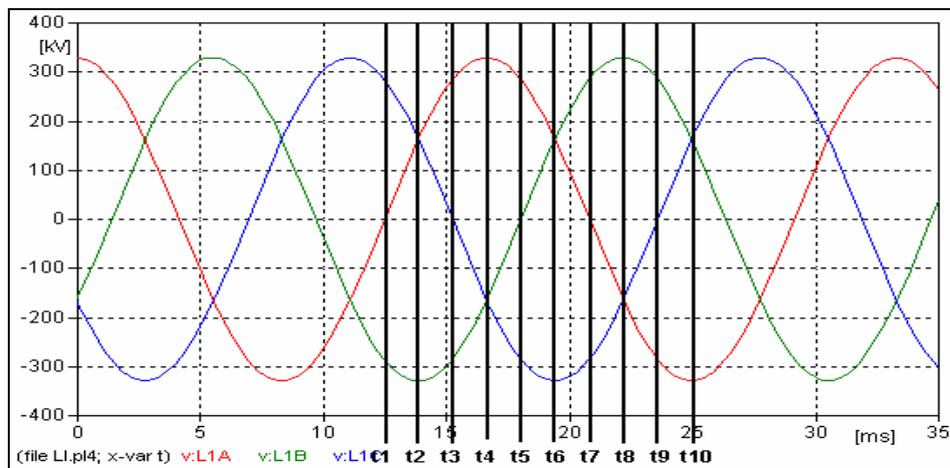


Fig. 5-4. Tiempos de cierre del Interruptor.



Tabla V. Tiempos de ocurrencia de la falta y ángulo respecto a la fase A.

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
tiempo (ms)	12.49	13.84	15.27	16.61	17.96	19.39	20.80	22.15	23.57	25.00
Angulo(°)	0	30	60	90	120	150	180	210	240	270

c.- Simulación computacional

El programa de simulación a utilizar es el EMTP/ATP en una versión especial con ampliación de memoria para modelos no lineales y líneas de transporte (Julio – 2003). El caso es, generado, ejecutado y post-procesado desde Matlab versión 6.5, a través del programa desarrollado mediante controles Active X, “MatAtp”.

Los modelos seleccionados, han sido:

- *Línea de Transmisión:*

Modelo de parámetros dependientes de la frecuencia (JMarti), con los siguientes ajustes: en frecuencia (0.01, 60 y 5000 Hz) a 9 décadas y 10 pasos por década.

- *Generadores:*

Modelo 14 de fuente senoidal a 60 Hz, 3 ϕ .

- *Equivalente Thévenin:*

Modelo de parámetros concentrados en secuencia (51).

- *Carga:*

Modelo RL por fase y sin acoplamiento.



- *Interruptores:*

Interruptores ideales controlados por tiempo, pero incorporando en lenguaje de programación un modelo dinámico del arco primario de falta, en aire. Este modelo será detallado al final de este punto.

- *Transformadores de corriente:*

Transformadores de dos devanados monofásicos (modelación por fase), saturables.

- *Transformadores de Tensión:*

Se modeló, un transformador ideal $N1:N2$, sin pérdidas ni saturación.

- *Modelo Dinámico del Arco Eléctrico en Aire (Implementación en MODELS/ATP):*

Existen diversos trabajos [12, 37, 38, 42, 147] donde se plantea el uso adecuado de modelos del arco primario de falta (y en algunos se adiciona el arco secundario cuando se estudian maniobras de recierre monopolar), para simular de una forma más real el comportamiento de las señales de tensión y corriente registradas en las barras de las subestaciones.

En [147], se plantea algo más específico, ligado a la influencia que puede tener el arco de falta sobre los algoritmos de localización de faltas. La conclusión es llamativa, pues indica que algoritmos modernos basados en métodos alternativos (onda viajera, diversificaciones de corriente, etc), no se alteran ante la existencia o no del arco eléctrico, mientras que los basados en la estimación de la impedancia de la línea, pueden llegar al 30% de error.

Esto justifica incorporar en nuestro estudio, la posibilidad de simular el arco de falta en aire, el cual puede representar un arco primario ocasionado por la ruptura de una cadena de aisladores o una falta de alta impedancia.



El modelo seleccionado, después de la revisión de [37, 109, 110, 111, 144, 145, 146 y 147], es el modelo de arco dinámico desarrollado por el Prof. Kizilcay.

El modelo es relativamente sencillo y el programa desarrollado en MODELS/ATP, se encuentra en los anexos del informe.

La ecuación del arco derivada desde un punto de vista de sistemas de control, está basada en el balance de energía en la columna del arco. Esta es escrita como:

$$\frac{dg}{dt} = \frac{1}{\tau}(G - g) \quad (5.2.1)$$

Donde:

g , es la conductancia variable con el tiempo.

G , es la conductancia estacionaria del arco y

τ , es la constante de tiempo.

G , es la conductancia que se mediría si la condición del arco primario fuera sostenida por un período largo de tiempo desde una fuente externa y puede ser representada mediante la siguiente función:

$$G = \frac{|i|}{(u_0 + R \cdot |i|) \cdot l} \quad (5.2.2)$$

Donde:

U_0 es una constante y es definida en por unidad de la longitud del arco.

R , es la componente resistiva del arco, en por unidad de longitud.

l , es la longitud del arco, la cual puede variar con el tiempo.

i , es la corriente del arco.

En general, para el arco primario, se asume que la longitud del arco es constante, dado el corto tiempo de interrupción. Los parámetros utilizados, se obtuvieron de [111], para un sistema de 380 kV, muy cercano al de la aplicación de este trabajo.

Tabla VI. Parámetros del arco eléctrico de falta (Primario)

Parámetro	Valor
U_0 (V/cm)	9.6
R (m Ω /cm)	1
τ (ms)	0.8
l (cm)	350

La solución de la ecuación diferencial, es ejecutada por medio de un método numérico disponible en el lenguaje MODELS de ATP, mediante la instrucción de LAPLACE ($LAPLACE(gp/G) := (1|s0) / (1|s0 + TAU|s1)$).

Y el modelo es incorporado al sistema como una resistencia variable controlada desde el lenguaje de programación (RTACS), tal como se muestra en la Fig 5-5.

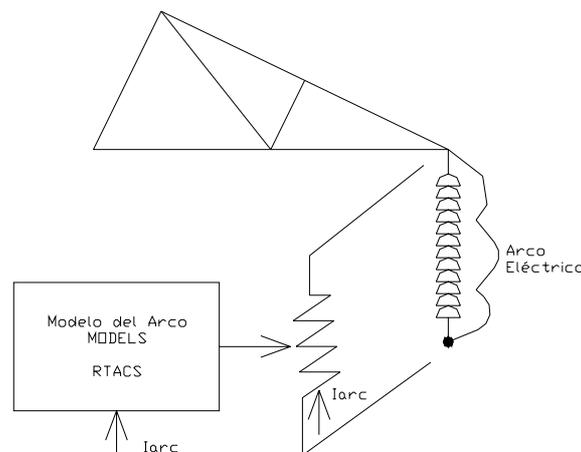


Fig. 5-5. Modelo del Arco Eléctrico (Primario), a través de una R variable, controlada desde MODELS.

En la Fig. 5-6, se muestra la respuesta del voltaje registrado en el punto de falta, con y sin el modelo de arco primario anteriormente descrito. Como puede notarse, aunque la falta sea a sólida a tierra como en el caso expuesto (voltaje nulo en el punto de falta), al incluir el modelo del arco, puede llegar a tener pico de hasta 15 kV (5% de la tensión pico base del sistema), lo cual favorece en cierta medida a la generación de ondas viajeras, aún ante bajos ángulos de inserción.

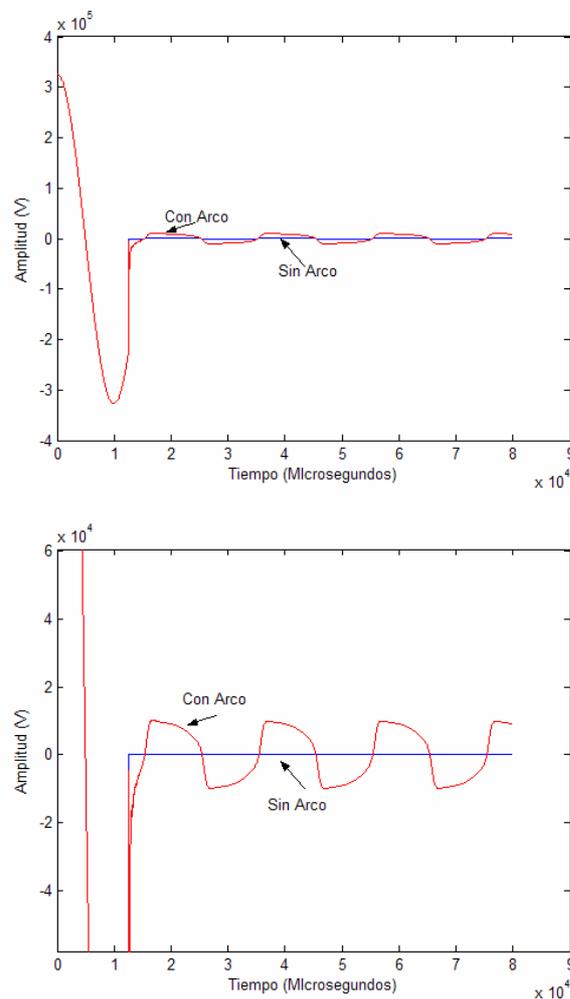


Fig. 5-6. Tensión en el punto de falta con y sin modelo del arco.



5.3.- Detección De La Falta

Lo más importante del algoritmo de detección, es establecer el valor del umbral de ajuste. Para ello, se simularon un total de 63 casos (tomando en cuenta solo los peores escenarios que fueron definidos con anterioridad).

Se tomó como localización de la falta, el nodo B3 (0%), dado que sería el peor caso para la detección en el nodo B2.

En las tablas VII-X, se resumen los resultados obtenidos, donde, $W_{\alpha f1}$ ó $W_{\beta f1}$, corresponden al mayor pico del MM de la transformada de la corriente modal (α ó β , respectivamente)

Tabla VII. Coeficientes máximos, Sin Falla.

Localización	Ang(°)	tint(s)	W α f1	W β f1
100%	0°	12.49	0.024	0.0235
	30°	13.84	--	--
	60°	15.27	--	--
	90°	16.61	--	--
	120°	17.96	--	--
	150°	19.39	--	--
	180°	20.8	--	--

Tabla VIII. Coeficientes máximos, Falla 1 ϕ (Rf=30 Ω).

Localización	Ang(°)	FA		FB		FC	
		W α f1	W β f1	W α f1	W β f1	W α f1	W β f1
100%	0°	0.96	0.96	47.86	0.02	0.02	46.92
	30°	13.39	13.39	26.68	0.02	0.02	13.29
	60°	23.36	23.36	22.84	0.02	0.02	0.53
	90°	54.72	54.72	27.39	0.02	0.02	27.33
	120°	23.32	23.32	0.43	0.02	0.02	22.89
	150°	13.31	13.31	13.37	0.02	0.02	26.68
	180°	0.27	0.27	48.21	0.02	0.02	47.92



Tabla IX. Coeficientes máximos, Falla 2φ

Localización	Ang(°)	FAB		FBC		FCA	
		Walf1	Wbet1	Walf1	Wbet1	Walf1	Wbet1
100%	0°	86.04	43.02	83.50	83.51	40.50	80.97
	30°	70.13	35.06	34.97	34.97	4.16	8.35
	60°	80.85	40.42	19.52	19.52	20.91	41.82
	90°	144.69	72.35	3.26	3.23	72.30	144.59
	120°	41.53	20.77	19.66	19.66	40.43	80.85
	150°	6.48	3.26	35.05	35.05	34.98	69.96
	180°	85.72	42.86	85.04	85.01	42.16	84.34

Tabla X. Coeficientes máximos, Falla 3φ

Localización	Ang(°)	FABC	
		Walf1	Wbet1
100%	0°	86.04	80.97
	30°	--	--
	60°	--	--
	90°	144.69	144.59
	120°	--	--
	150°	--	--
	180°	85.72	84.34

Se puede observar que es necesario, tanto los coeficientes de la componente β, como de la α, ya que hay casos donde uno resalta sobre el otro y viceversa.

Adicionalmente, el factor más alto para el caso: Sin Falta, corresponde a:

$$SF_{\text{máx}} = \underline{0.024}$$

Y el caso más pequeño (combinando el máximo entre α y β), es:

$$CF_{\text{mín}} = \underline{0.27}$$

Así que el ajuste debe estar en el siguiente rango:

$$\mathbf{0.024 < Maj < 0.27}$$

Por lo que puede tomarse para ser conservador, un valor de **Maj = 0.05**.



5.4.- Clasificación Del Tipo De Falta

Una vez detectada, se deja pasar $\frac{1}{2}$ ciclo y con esa ventana (de también $\frac{1}{2}$ ciclo), se obtiene el vector que se introducirá a la red neuronal, para su clasificación.

Primeramente, debe resaltarse, que previo a la implementación final del algoritmo, se realizaron los casos bases de entrenamiento para la red neuronal. En total fueron generados 3630 casos, bajo la siguiente variación de parámetros.

- *Impedancia de Falta (3 casos):*

$$R_f = [0, 10 \text{ y } 30] \Omega$$

- *Angulo de inserción (expresado en tiempo de cerrado del interruptor): (11 casos)*

$$T_c = [1.63E-3 \ 3.31E-3 \ 4.97E-3 \ 6.57E-3 \ 8.31E-3 \ 10E-3 \ 11.63E-3 \ 13.3E-3 \ 14.96E-3 \ 16.65E-3 \ 18.3E-3] \text{ s.}$$

- *Localización de la falta: (11 casos)*

$$D_f = [1 \ 10 \ 20 \ 30 \ 40 \ 50 \ 60 \ 70 \ 80 \ 90 \ 99] \text{ Km}$$

- *Tipo de falta: (10 casos)*

$$TF = [FAT \ FBT \ FCT \ FABT \ FBCT \ FCAT \ FAB \ FBC \ FCA \ FAB]$$

Parte del archivo que contiene los 3630 vectores de entrenamiento, se encuentra en el anexo.



Luego de entrenada la red, se hicieron dos comprobaciones:

a.- Verificación del ajuste de la red:

Se logró un error en el entrenamiento del 0%, es decir, que al simular la red con alguno de los casos utilizados para el entrenamiento, la clasificación era la adecuada.

b.- Verificación con valores intermedios (simulaciones o casos no incluidos en el entrenamiento):

En la siguiente tabla se colocan alguno de los resultados obtenidos al introducir vectores aleatorios a la red neuronal para su clasificación.

Tabla XI. Pruebas de la red neuronal, para la clasificación de la falta

Rf (Ohm)	Df (Km)	Angulo (°)	Tipo Falta	Cclobin	Ccia	Cclb	Cclc	Salida Red	Error
0	5	30	FAB	0	1	0.0361	0.9926	0110	0
0	5	60	FBT	1	0.2188	1	0.2336	1010	0
0	15	180	FCT	1	0.2289	0.2318	1	1001	0
0	25	0	FAT	1	1	0.5623	0.2318	1100	0
10	35	0	FCAT	1	0.925	0.0383	1	1101	0
10	35	30	FAB	0	1	0.9926	0.0324	0110	0
10	35	0	FCA	0	0.9882	0.0415	1	0101	0
10	55	60	FABC	0	0.853	1	0.7905	0111	0
10	55	60	FCT	1	0.2077	0.2044	1	1001	0
10	55	90	FABT	1	1	0.9565	0.0383	1110	0
10	65	90	FBCT	1	0.0425	1	0.8959	1011	0
10	65	90	FBT	1	0.2115	1	0.2221	1010	0
0	75	30	FCT	1	0.2233	0.2201	1	1001	0
0	75	0	FCA	0	1	0.42	0.8068	0101	0
0	85	0	FAT	1	1	0.2519	0.2436	1100	0
0	85	0	FBT	1	0.4228	1	0.4391	1010	0
0	85	180	FCT	1	0.3979	0.3743	1	1001	0
0	95	90	FCAT	1	0.9255	0.126	1	1101	0
30	95	60	FCAT	1	1	0.0346	0.9956	1101	0
30	95	30	FAT	1	1	0.1471	0.1355	1100	0
30	15	60	FBT	1	0.2276	1	0.2425	1010	0
30	15	30	FABT	1	1	0.9606	0.0573	1110	0
30	15	30	FBT	1	0.3751	1	0.2916	1010	0
30	35	0	FCT	1	0.3516	0.3465	1	1001	0
0	35	0	FABT	1	1	0.9412	0.0795	1110	0
0	35	30	FBCT	1	0.1324	1	0.8579	1011	0
0	55	0	FCA	0	0.9831	0.1263	1	0101	0
10	55	0	FCA	0	0.7475	0.3274	1	0101	0



Se ensayó con 100 casos adicionales, seleccionando localizaciones de falta distintas a las utilizadas para el entrenamiento, clasificando siempre de forma correcta.

El problema evidenciado durante las simulaciones, es que la red entrenada con tantos casos es muy pesada computacionalmente, ya que almacena todos los vectores de para la comparación con los nuevos valores introducidos. Por ello, se sugiere probar a futuro con una red neuronal menos pesada como una con arquitectura BP, ya que solo se almacena el valor de los pesos de ajuste de las funciones de activación.

Sin embargo, cabe resaltar que no se probó el comportamiento de la red con menor número de casos de entrenamiento.

La desventaja final, es que limita fuertemente su disponibilidad para aplicaciones en línea.

5.5.- Discriminación Del Tipo De Falta

Este es el caso más sencillo de comprobar, pues solo se necesita la polaridad del primer pico del MM, tanto de la señal de tensión como de la de corriente, para el modo α , según la selección de la matriz de transformación.

Así que se probaron un grupo de escenarios (100 casos), encontrándose como críticas aquellos relacionados a bajos ángulos de inserción. En la Fig. 5-7, se observa uno de los casos, donde la relación entre la magnitud del primer pico del MM de la señal de corriente es 100000 más grande que el de la tensión. Sin embargo, el criterio establecido es válido, para establecer la direccionalidad de la falta.

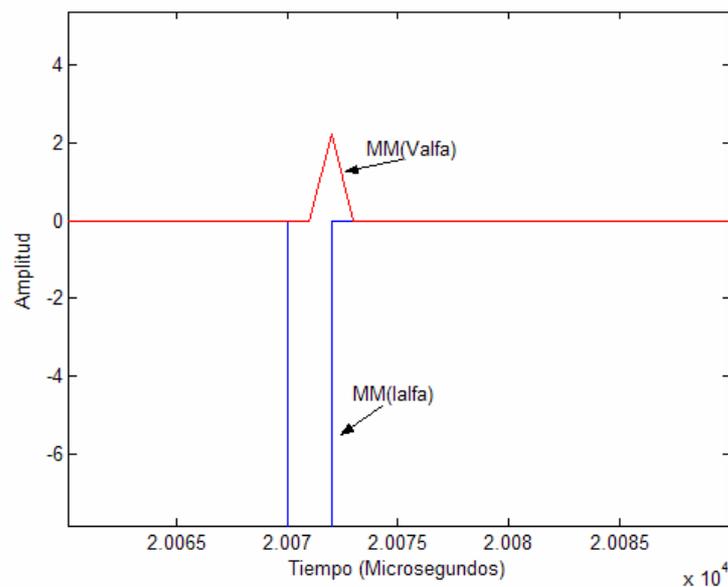


Fig. 5-7. Polaridad de los primeros picos del MM de $V\alpha$ e $I\alpha$, para un ángulo de inserción de 0° , para una falta interna.

Igualmente, se presenta el mismo caso, pero para una falla hacia atrás del punto de medición. (Fig. 5-8).

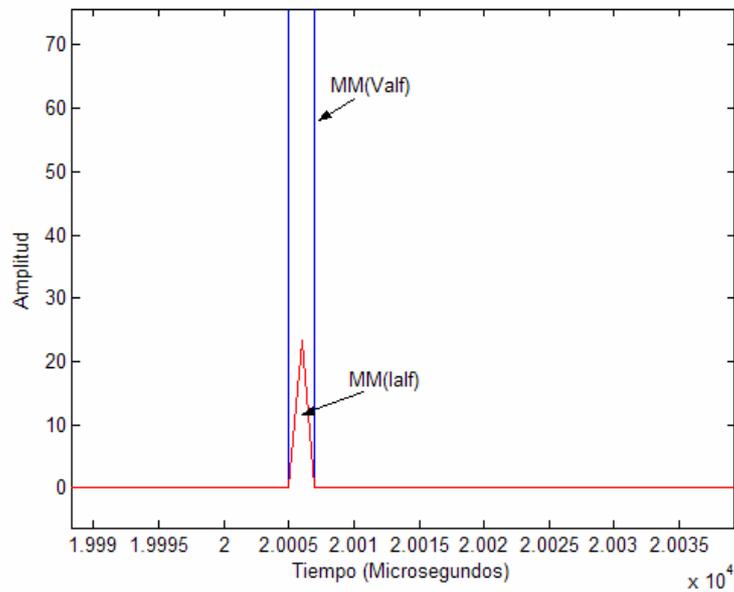


Fig. 5-8. Polaridad de los primeros picos del MM de $V\alpha$ e $I\alpha$, para un ángulo de inserción de 0° , para una falta externa.

En la tabla XII, se resumen algunos resultados obtenidos, de todos los casos evaluados.

Tabla XII. Resultados para la discriminación direccional.

Tipo de Falta	Df (Km)	Angulo ($^\circ$)	Pol MM($V\alpha$)	Pol MM($I\alpha$)
FAT	15	0	+	-
FBT	35	0	-	+
FCT	Externa	0	-	-
FABT	95	0	+	-
FBCT	55	0	-	+
FCAT	75	0	+	-
FAB	Externa	0	+	+
FBC	35	0	-	+
FCA	Externa	0	-	-
FABC	35	0	+	-



5.6.- Localización De La Falta.

Para la localización de la falta, se entrenó la red neuronal del tipo función base radial, con los mismos 3630 casos que fueron utilizados para la tarea de clasificación, pero determinando un nuevo vector de entrenamiento V_L , definido con anterioridad.

Para recordar, el vector V_L , está compuesto por la información de la posición y polaridad de los primeros seis (6) picos del MM de la señal de voltaje modal (donde la selección de la matriz de transformación depende del tipo de falta).

a.- Verificación del ajuste de la red:

Cabe indicar que ciertos casos con ángulos de inserción de cero grados, no dan información confiable para la localización directa por onda viajera. Sin embargo, fueron incluidos como información en la red neuronal, para observar la capacidad de generalización.

Los resultados del entrenamiento, arrojaron errores promedio de 1% y errores máximos de 300%. Esto indica que para ciertos casos, se logra un buen resultado, pero para otros como los mencionados anteriormente, el modelo no logra generalizarlos.

El problema del error, es reducido sustancialmente cuando se sacan del entrenamiento todos aquellos casos con ángulos de inserción de 0 y 30°, arrojándose un error promedio de 0.1% y errores máximos de 3%. Sin embargo, al simular la red para casos con bajos ángulos de inserción (no incluidos en el entrenamiento), los errores son significativos.

Así que no se consigue una solución intermedia, pues la localización por el principio de onda viajera, tiene problemas severos para bajos ángulos de inserción, aclarando que especialmente cuando en la simulación computacional no se incluye el modelo del arco primario de falta.



También cabe la pena indicar que tras una observación minuciosa de ciertos casos, se pudo verificar que el problema de localización en bajos ángulos de inserción tiene especial relevancia para las faltas a tierra (monofásicas y bifásicas), teniendo buenos resultados para el resto de las faltas.

A continuación se presentan un grupo de figuras, donde se determina de forma gráfica la localización de la falta, a partir de la información suministrada por el MM de $V\alpha$, con la matriz de transformación apropiada y que ayudan a entender el orden de los valores introducidos en el vector de localización, bien sea para el entrenamiento o para la determinación real de Df .

Puede observarse que para el primer grupo (Fig. 5-9 a 5-18), donde la distancia de falta es pequeña (5 Km), la determinación es sencilla, pues el pico que sigue al inicial, siempre corresponde al proveniente del rebote con la barra de medición y no hay nada intermedio, pues los tiempos de viaje asociados con las ondas viajeras que llegan a la otra barra, son muy grandes en comparación con éste (p.e. 2 tv en este caso corresponde a 33 μ s, mientras que el tiempo de viaje desde el punto de falta hasta la otra barra, es de 316 μ s).

Sin embargo, para faltas con $Df > 50\%$ de la longitud de la línea, existen ondas previas a la correspondiente de $2tv$, que no pueden ser identificadas con demasiada facilidad, especialmente para faltas monofásicas. Eso justifica en parte el uso de la red neuronal. Sin embargo, puede ser previsible en función de algunos aspectos explicables a través de un análisis del diagrama de Bewley (o Lattice). De forma simplificada, puede resumirse de la siguiente manera (con ayuda de las Fig. 5-19 a 5-21 y especialmente de la 5-29):

En faltas monofásicas con $Df < 50\% L$:

- La cantidad de puntos detectados en el MM es grande y en pasos relativamente constantes, producto de las constantes reflexiones en la barra más cercana (la de medición).



- El segundo mayor pico, corresponde a la llegada de la onda viajera de falta después de su reflexión en la barra de medición ($2tv$).
- El tercer mayor pico, corresponde a la primera onda proveniente de la barra lejana.

En faltas monofásicas con $Df > 50\% L$:

- La cantidad de puntos detectados en el MM es pequeña (gran dispersidad) y en pasos no constantes.
- El segundo mayor pico, corresponde a la reflexión de la onda viajera en la barra lejana a la medición, pues ésta es la más cercana al punto de falta, lo que implica directamente un menor tiempo de viaje.
- El tercer mayor pico, corresponde a la llegada de la onda viajera de falta después de su reflexión en la barra de medición ($2tv$).

Para el resto de tipos de faltas (bifásicas, bifásicas a tierra y trifásicas), no hay problema en la determinación de la distancia a la falta, pues siempre el segundo mayor pico corresponde a la reflexión de la onda de interés ($2 tv$). Esto siempre y cuando haya sido seleccionada apropiadamente la matriz de transformación modal de Karrenbauer (ver Fig. 5-22 a 5-28).

Todas estas observaciones, ayudan a que con poca cantidad de puntos como los seleccionados para el vector V_L , se tenga la certeza de conseguir el pico correspondiente a la reflexión de interés (en este caso se seleccionaron 6).

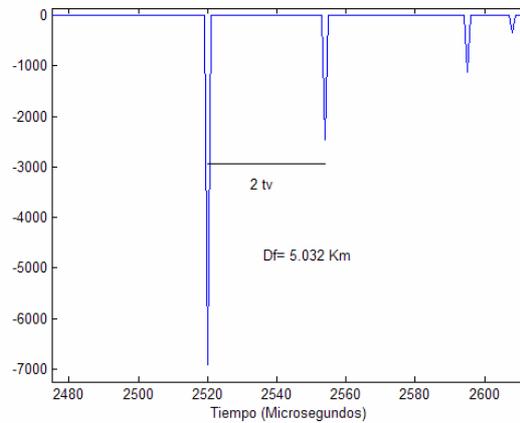


Fig.5-9. Respuesta del MM (Va) para una falta FAT a 5 Km. Angulo = 30° y Rf=30Ω.

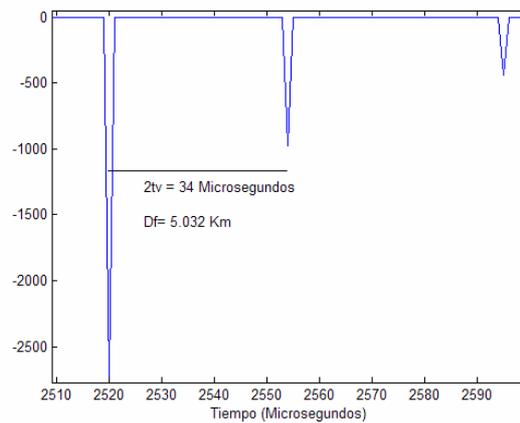


Fig.5-10. Respuesta del MM (Va) para una falta FBT a 5 Km. Angulo = 30° y Rf=30Ω.

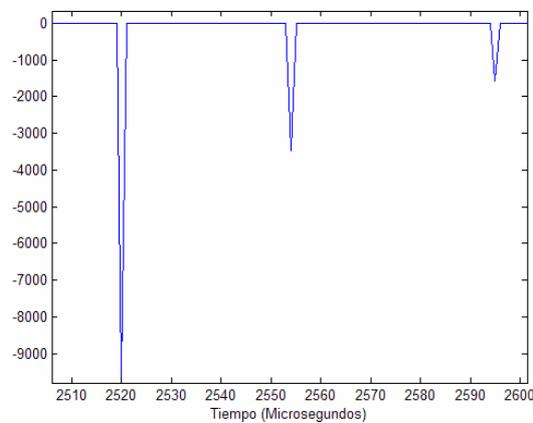


Fig.5-11. Respuesta del MM (Va) para una falta FCT a 5 Km. Angulo = 30° y Rf=30Ω.

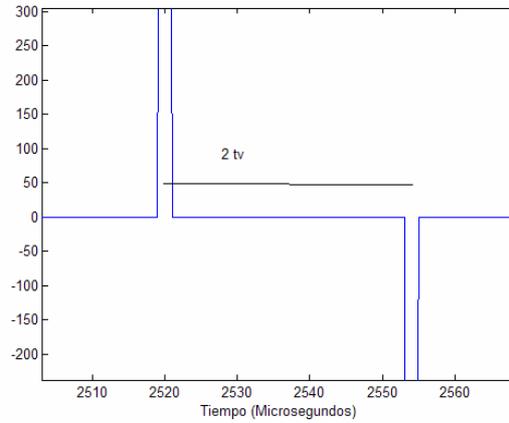


Fig.5-12. Respuesta del MM(Va) para una falta FABT a 5 Km. Angulo= 30° y Rf=30Ω.

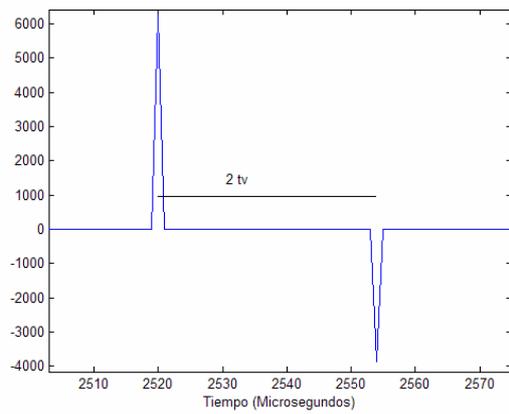


Fig.5-13. Respuesta del MM(Va) para una falta FBCT a 5 Km. Angulo= 30° y Rf=30Ω.

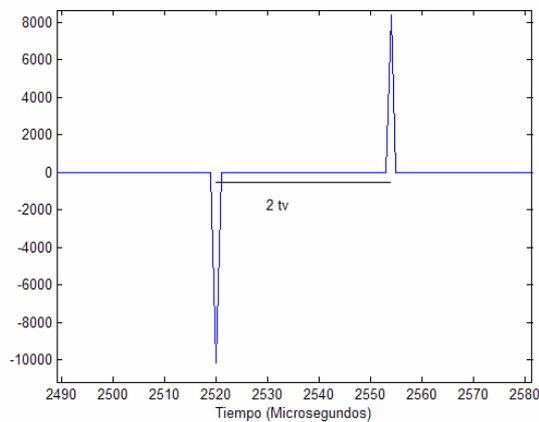


Fig.5-14. Respuesta del MM(Va) para una falta FCAT a 5 Km. Angulo= 30° y Rf=30Ω.

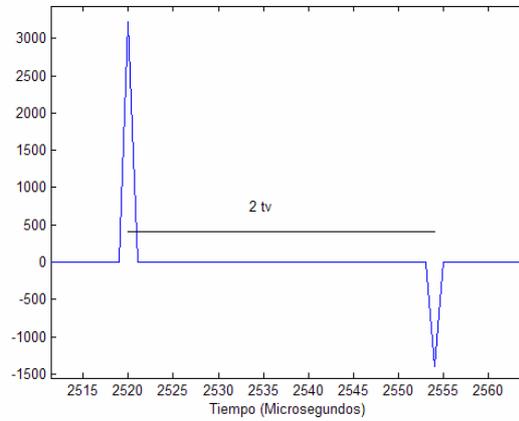


Fig.5-15. Respuesta del MM (Va) para una falta FAB a 5 Km. Angulo = 30° y Rf=30Ω.

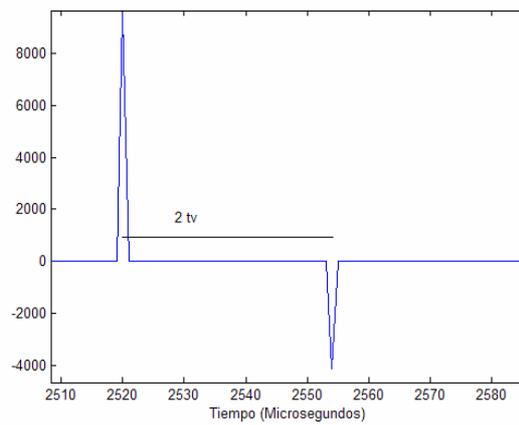


Fig.5-16. Respuesta del MM (Va) para una falta FBC a 5 Km. Angulo = 30° y Rf=30Ω.

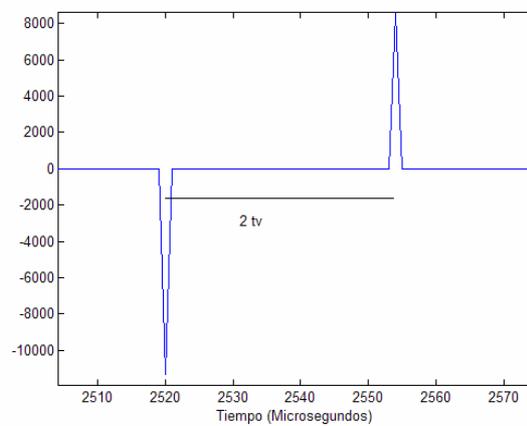


Fig.5-17. Respuesta del MM (Va) para una falta FCA a 5 Km. Angulo = 30° y Rf=30Ω.

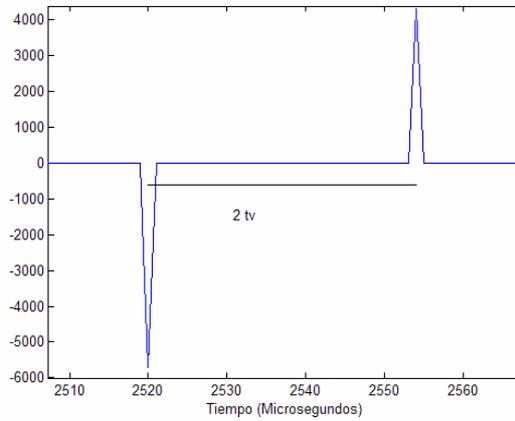


Fig.5-18. Respuesta del MM(Va) para una falta FABC a 5 Km. Angulo= 30° y Rf=30Ω.

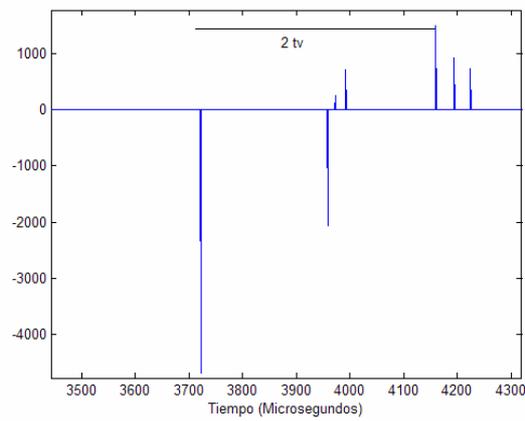


Fig.5-19. Respuesta del MM (Va) para una falta FAT a 65 Km. Angulo=60° y Rf=30Ω.

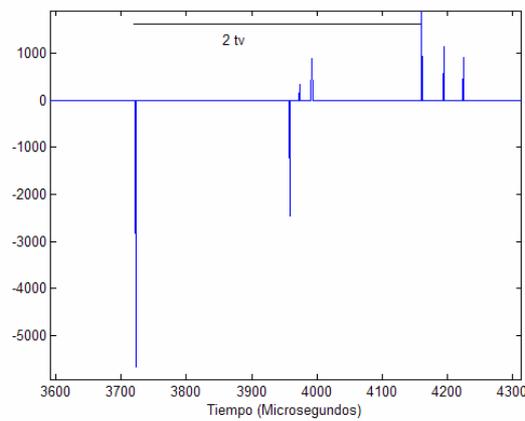


Fig.5-20. Respuesta del MM (Va) para una falta FBT a 65 Km. Angulo=60° y Rf=30Ω.

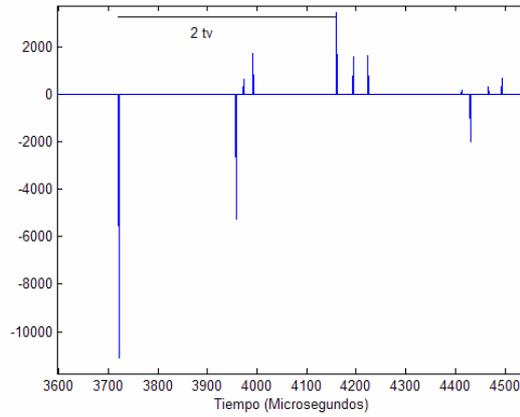


Fig.5-21. Respuesta del MM (Va) para una falta FCT a 65 Km. Angulo=60° y Rf=30Ω.

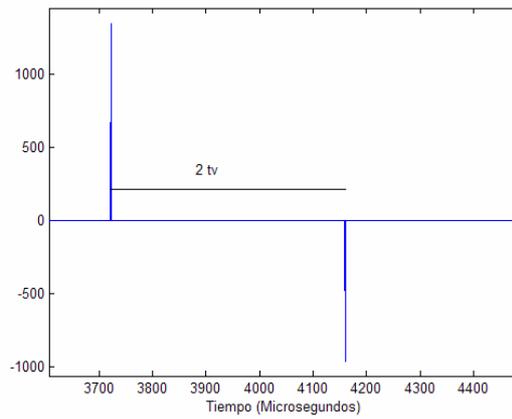


Fig.5-22. Respuesta del MM(Va) para una falta FABT a 65 Km. Angulo=60° y Rf=30Ω.

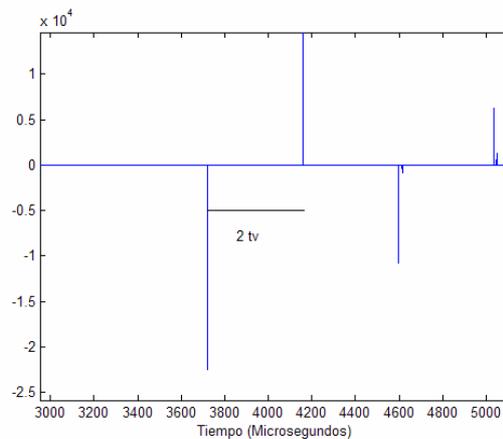


Fig.5-23. Respuesta del MM(Va) para una falta FBCT a 65 Km. Angulo=60° y Rf=30Ω.

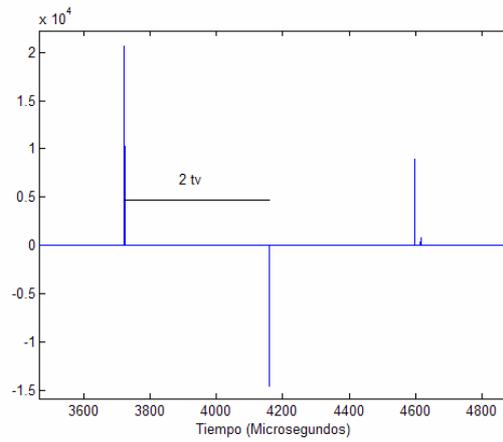


Fig.5-24. Respuesta del MM(Va) para una falta FCAT a 65 Km. Angulo=60° y $R_f=30\Omega$.

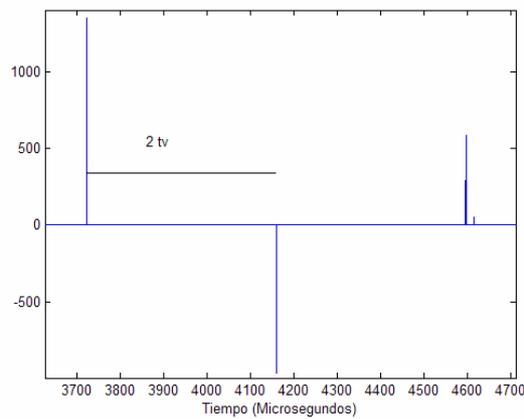


Fig.5-25. Respuesta del MM (Va) para una falta FAB a 65 Km. Angulo = 60° y $R_f=30\Omega$.

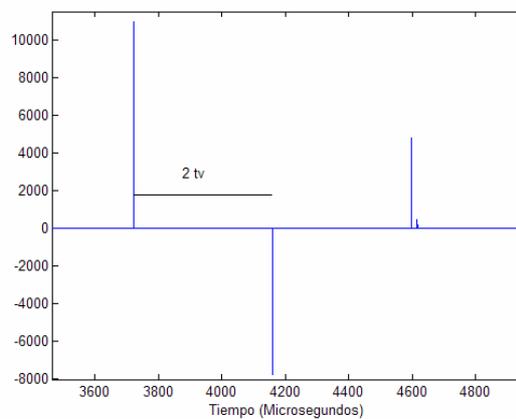


Fig.5-26. Respuesta del MM (Va) para una falta FBC a 65 Km. Angulo=60° y $R_f=30\Omega$.

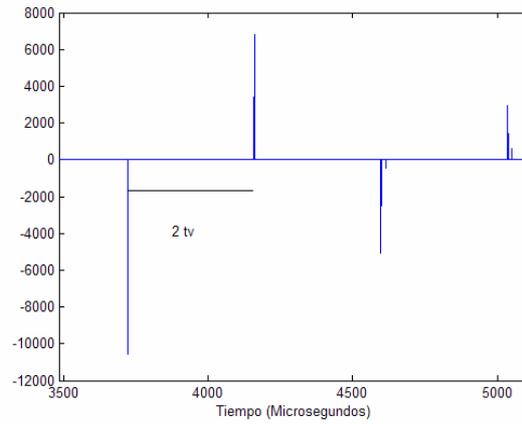


Fig.5-27. Respuesta del MM (Va) para una falta FCA a 65 Km. Angulo =60° y $R_f=30\Omega$.

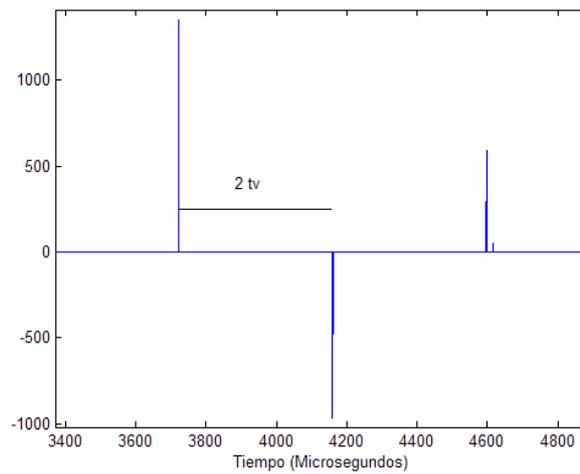
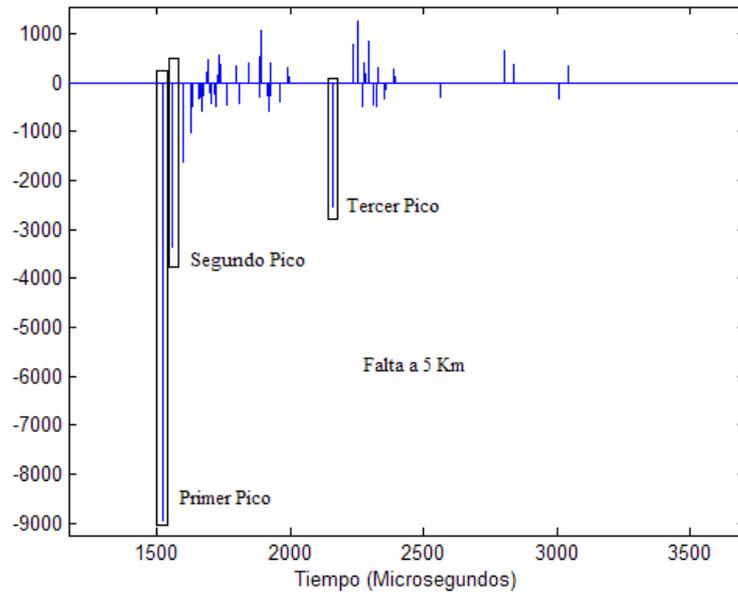
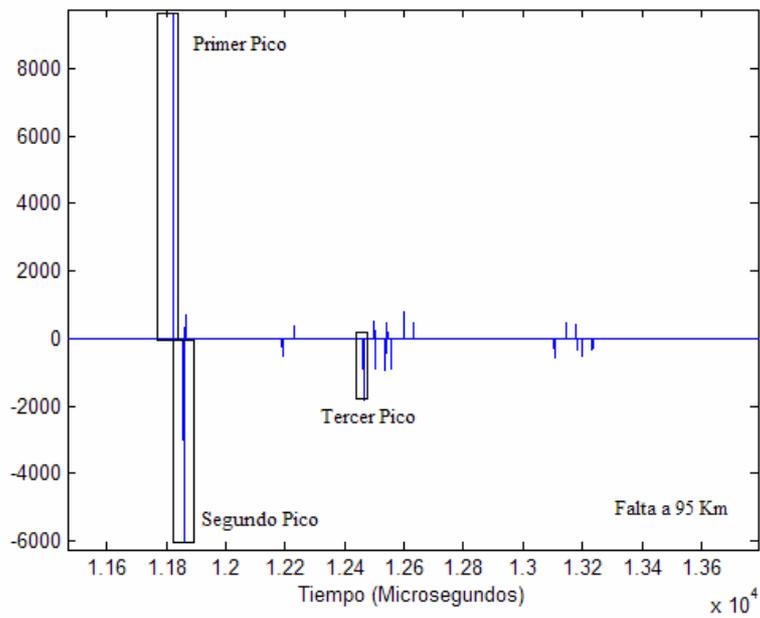


Fig.5-28. Respuesta del MM(V_α) para una falta FABC a 65 Km. Angulo=60° y $R_f=30\Omega$.



(a)



(b)

Fig.5-29. Respuesta del MM(Va) para una falta FAT. (a) a 5 Km, (b) a 95 Km.



b.- Verificación con valores intermedios (simulaciones o casos no incluidos en el entrenamiento):

En la tabla XII se colocan alguno de los resultados obtenidos al introducir vectores aleatorios a la red neuronal para su clasificación. Cabe indicar que se ha incluido una columna adicional denominada (Estimado 2); esta es la distancia obtenida con el método del perfil ficticio de tensiones descrito en el capítulo anterior y que demuestra su utilidad y buenos resultados en prácticamente todos los casos que fueron ensayados.

Tabla XII. Resultados de localización.

Tipo de Falta	Angulo (°)	Rf (Ohm)	Df (Km)	Salida1 (Km)	Error (%)	Estimado 2 (Km)
FAT	60	30	5	5.1	0.1	5.01
FBT	60	30	5	5.1	0.1	5.01
FCT	60	30	5	5.1	0.1	5.01
FABT	60	30	5	5.1	0.1	5.01
FBCT	60	30	5	5.1	0.1	5.01
FCAT	60	30	5	5.1	0.1	5.01
FAB	60	30	5	5.1	0.1	5.01
FBC	60	30	5	5.1	0.1	5.01
FCA	60	30	5	5.1	0.1	5.01
FABC	60	30	5	5.1	0.1	5.01
FAT	30	0	35	--	>100	34.8
FBT	30	0	35	--	>100	34.8
FCT	30	0	35	--	>100	34.8
FABT	30	0	35	--	>100	34.8
FBCT	30	0	35	--	>100	34.8
FCAT	30	0	35	--	>100	34.8
FAB	30	0	35	37.3	2.32	35
FBC	30	0	35	35.8	0.78	35
FCA	30	0	35	36.2	1.17	35
FABC	30	0	35	35.5	0.51	35
FAT	0	30	85	--	>100	82
FBT	0	30	85	89.1	4.14	82
FCT	0	30	85	92.9	7.95	80
FABT	0	30	85	--	>100	80
FBCT	0	30	85	93.3	8.30	80
FCAT	0	30	85	--	>100	80
FAB	0	30	85	92.9	7.95	84
FBC	0	30	85	90.2	5.24	84
FCA	0	30	85	89.1	4.14	84
FABC	0	30	85	92.3	7.33	84



6.- CONCLUSIONES

En el presente trabajo se inició una línea de investigación ligada a la protección posicional de líneas de transporte en alta tensión, utilizando técnicas modernas de análisis, como las redes neuronales y la transformada wavelets. Entendiéndose como posicional, la búsqueda de la localización precisa de la falta en el sistema eléctrico de potencia.

Tras la revisión bibliográfica evaluada, se justifica el uso de la transformada wavelets, como una herramienta poderosa, tanto para la detección de singularidades en señales y como filtro para extraer bien sean las componentes de alta frecuencia o la componente a frecuencia fundamental, para su posterior procesamiento en técnicas de onda viajera o fasoriales. También se justifica el uso de las redes neuronales como técnica importante en reconocimiento de patrones e identificación de eventos.

Para ello, en el trabajo se realizó una breve descripción de los fundamentos prácticos de la transformada wavelets, con especial interés en la discreta (multi-resolución) y en la continua compleja. Adicionalmente, se desarrolló un subcapítulo ligado a las redes neuronales, estableciendo la simplicidad de su implementación algorítmica, específicamente para las arquitecturas probabilística, retropropagación y función de base radial.

Se considera que la división del algoritmo de localización en cuatro tareas fundamentales: detección, clasificación, discriminación direccional y la localización, era la forma adecuada de buscar las mejores alternativas en cuanto a técnicas de análisis para cada una de ellas, en relación con las técnicas más modernas publicadas internacionalesmente.

Para cada tarea, finalmente se desarrolló un algoritmo concatenado, el cual fue implementado en Matlab, a fin de tener disponibles las librerías necesarias, tanto para las distintas transformadas wavelets utilizadas, como para las arquitecturas de redes neuronales necesarias.



Se realizó una descripción de las Principales herramientas de interés que podían ser utilizadas no solo en el algoritmo a implementar, sino en muchas otras aplicaciones no necesariamente ligadas al mismo tema (pues se desarrollaron de forma generalizable); así se presentó una breve descripción del fenómeno de onda viajera, de la transformación modal (real y compleja) y su aplicación en señales instantáneas, la obtención de cantidades fasoriales y valores efectivos a partir del análisis multi-resolución y algunas técnicas para favorecer ostensiblemente la información suministrada por la transformación de wavelets, como el Modulus Maxima.

La herramienta que fue seleccionada para la obtención de las formas de onda de corrientes y tensiones en el sistema, es el programa de transitorios electromagnéticos en su versión libre ATP.

Cabe resaltar el desarrollo de una interfaz para la simulación de los casos en EMTP/ATP, a través de Matlab, lo cual permitió ejecutar una cantidad considerable de casos, de forma automatizada y sistemática. Esto facilita el uso de la herramienta y permite obtener resultados importantes en cortos períodos de tiempo. Debe indicarse que la interfaz desarrollada, permite crear los casos, ejecutarlos y postprocesarlos desde Matlab, no siendo necesario el conocimiento por parte del usuario de los detalles propios del ATP. Dicha herramienta ha servido como aporte al grupo de desarrollo del ATP y actualmente se encuentra disponible en el servidor para usuarios con licencia.

Se incorporó un modelo dinámico de arco eléctrico al ATP, para hacer mas realistas los resultados que pudieran ser obtenidos de las distintas simulaciones efectuadas.

Por último, la herramienta desarrollada, fue probada para un caso base sencillo, obteniéndose resultados favorables en cada una de las tareas.

En particular, la tarea de clasificación con el algoritmo implementado en apoyo a una red neuronal del tipo probabilística, demostró tener un buen comportamiento, no



encontrándose ningún caso en el que la falta no pudiese ser clasificada de forma correcta.

Adicionalmente se comprobó el buen funcionamiento del algoritmo de discriminación direccional, el cual tiene como propiedad interesante, su extremada sencillez y robustez, al basarse en técnicas convencionales relacionadas con la direccionalidad de la energía.

Para el caso de la localización, se encontró que un algoritmo basado únicamente en ondas viajeras, no permite cubrir de forma confiable todos los posibles casos que pueden presentarse en un sistema, especialmente los relacionados con bajos ángulos de inserción. Y esto aún en el caso de la incorporación del modelo de arco. Sin embargo, se probó de forma manual, el algoritmo de localización basado en el análisis de la distribución del potencial ficticio en la línea, utilizando en modelo de parámetros distribuidos o solución de la ecuación del telegrafista, demostrando un gran potencial para localizar todo tipo de falta, incluso con gran exactitud en aquellos casos no detectables por el algoritmo de onda viajera.

Como conclusión final, debe resaltarse que los mejores resultados y así lo demuestran las últimas tendencias en los trabajos publicados recientemente, se logran con algoritmos que involucren lo mejor de la información que se puede obtener con las técnicas de alta y baja frecuencia. Por ello, es recomendable seguir con el temario, haciendo hincapié en la incorporación efectiva de técnicas mixtas.



7.- FUTUROS TRABAJOS

En función de los resultados obtenidos y de las conclusiones anteriores, podrían plantearse diversidad de temas que deberían ser profundizados para una búsqueda mas minuciosa de las mejores técnicas de análisis, como por ejemplo:

- Realizar una comparación entre la transformada wavelet y la de Fourier, para el caso de obtención de valores efectivos y cantidades fasoriales y así determinar si la herramienta utilizada en este trabajo, representa alguna ventaja significativa. Si bien existen algunos trabajos a este respecto, no se entra con demasía en los detalles.
- Mejorar la técnica de localización basada en la distribución ficticia del potencial de la línea de transporte, especialmente en lo relacionado a la cantidad de cómputo, automatización, etc. Y se recomienda su interfaz con una red neuronal.
- Incorporar técnicas de lógica difusa, especialmente las de relaciones lógicas (if-then) para el algoritmo de clasificación y así comparar el comportamiento con la técnica utilizada en este trabajo.
- Desde el punto de vista de modelación de la red, debe incorporarse un modelo más realista del divisor de tensión utilizado para la medición y comprobar si limita y en qué medida a los algoritmos desarrollados.
- Incorporar algunas de las herramientas desarrolladas para la localización de faltas en media tensión.
- Y por último, probar el algoritmo con señales reales obtenidas de oscilógrafos instalados en subestaciones eléctricas de la red española y en los que se tenga suficiente información en cuanto a las características de la falta y su ubicación.



8.- BIBLIOGRAFIA

- [1] A. Phadke, J. Thorp. "Computer Relaying for Power Systems". Research Studies Press LTD., 1988.
- [2] A.T.Johns, J.R.Platts. "Digital Protection for Power Systems". IEE Power Series 15. 1996.
- [3] IEEE Tutorial. "Advances in Microprocesor Relaying". IEEE Press. 2000.
- [4] Chen, Z.; Bo, Z.Q.;" Developments in directional power line protection using fault transients". Power System Technology Conference, 2002. Volume: 1, 13-17 Oct 2002. pp: 304 -308
- [5] D. Proudfoot. "UCA and 61850 for Dummies". Siemens Transmission and Distribution. 2002.
- [6] Li, H.Y.; Crossley, P.A.; Aggarwal, R.K." Application of fibre optical current transducer to protection" Sixth International Conference on Developments in Power Protection. pp: 274 - 277
- [7] Tziouvaras, D.A.; McLaren, P., et al.;" Mathematical models for current, voltage, and coupling capacitor voltage transformers" IEEE Transactions on Power Delivery, Volume: 15 Issue: 1 , Jan. 2000, pp: 62 -72
- [8] Transmission & Distribution, Relaying Application Guide. ALSTOM 2004.
- [9] Bo, Z.Q.; Jiang, F.; Chen, Z.; Dong, X.Z.; Weller, G.; Redfern, M.A.;" Transient based protection for power transmission systems" Power Engineering Society Winter Meeting, 2000. IEEE , Volume: 3 , 23-27 Jan. 2000.
- [10] Jyh-Cherng Gu; Sun-Li Yu. "Removal of DC offset in current and voltage signals using a novel Fourier filter algorithm" IEEE Transactions on Power Delivery Volume: 15, Issue: 1, Jan 2000.
- [11] Pathirana, V.; McLaren, P.G.; Dirks, E.;" Investigation of a hybrid travelling wave/impedance relay principle ", Electrical and Computer Engineering, 2002. IEEE CCECE 2002. Canadian Conference on , Volume: 1 , 12-15 May 2002
- [12] Bo, Z.Q.; Redfern, M.A.; Weller, G.C." Positional protection of transmission line using fault generated high frequency transient signals" IEEE Transactions on Power Delivery Volume: 15, Issue: 3, Jan 2000.
- [13] Sun-Li Yu; Jyh-Cherng Gu. "Removal of decaying DC in current and voltage signals using a modified Fourier filter algorithm" IEEE Transactions on Power Delivery Volume: 16, Issue: 3, Jan 2001.
- [14] Mladen Kezunovic Bogdan Kasztenny Zijad Galijasevic. "Modeling, Developing and Testing Protective Relays using MATLAB". ICDS 99.
- [15] Kezunovic, M.; Chen, Q.; "A novel approach for interactive protection system simulation" Transmission and Distribution Conference, 1996. Proceedings IEEE , 15-20 Sep 1996. pp 458 -464.
- [16] Kezunovic, M.; Chen, Q.; "A novel approach for interactive protection system simulation" IEEE Transactions on Power Delivery, Volume: 12 Issue: 2 , Apr 1997. Page(s): 668 -674



- [17] Kezunovic, M.; Pickett, B.A.; Adamiak, M.G.; Alexander, G.E.; Carr, K.R.; Chirco, G.; Esztergalyos, J.; Jerolimski, M.; Kotheimer, W.C.; Marttila, R.; McElray, J.L.; McKenna, S.M.; McLaren, P.G.; Murphy, R.J.; Nordstrom, J.; Ryan, R.; Skendzic, V.; "Digital Simulator Performance Requirements for Relay Testing" Power Delivery, IEEE Transactions on , Volume: 13 Issue: 1 , Jan 1998
Page(s): 78 -84
- [18] M. Kezunovic, T. Popovic, D. Sevcik, and H. DoCarmo. "Transient Testing of Protection Relays: Results, Methodology and Tools" IPST 2003
- [19] Claus, M.; Lemmer, S.; Ziegler, G. « Proceedings in distance relaying". Sixth International Conference on Developments in Power Protection 1997.
- [20] Saha, M.M.; Wikstrom, K.; Lindahl, S." A new approach to fast distance protection with adaptive features" Sixth International Conference on Developments in Power Protection. 1997.
- [21] Mechraoui, A.; Thomas, D.W.P." A new distance protection scheme which can operate during fast power swings" Sixth International Conference on Developments in Power Protection 1997.
- [22] Centeno, V.; Phadke, A.G.; Edris, A "Adaptive out-of-step relay with phasor measurement" Sixth International Conference on Developments in Power Protection 1997.
- [23] Akke, M.; Thorp, J.S. "Improved estimates from the differential equation algorithm by median post-filtering" . Sixth International Conference on Developments in Power Protection 1997.
- [24] Thomas, D.W.P.; Woolfson, M.S." Voltage and current phasor estimation during abnormal conditions for transmission line protection schemes" Sixth International Conference on Developments in Power Protection 1997.
- [25] Song, Y.H.; Johns, A.T.; Xuan, Q.Y.; Liu, J.Y." Genetic algorithm based neural networks applied to fault classification for EHV transmission lines with a UPFC" . Sixth International Conference on Developments in Power Protection 1997.
- [26] Sidhu, T.S.; Singh, H.; Sachdev, M.S. "An artificial neural network for directional comparison relaying of transmission lines" Sixth International Conference on Developments in Power Protection 1997.
- [27] Qi, W.; Swift, G.; McLaren, P. "Distance protection using an artificial neural network" Sixth International Conference on Developments in Power Protection 1997.
- [28] Kasztenny, B.; Rosolowski, E.; Lukowicz, M.; Izykowski, J." Current related relaying algorithms immune to saturation of current transformers" Sixth International Conference on Developments in Power Protection 1997.
- [29] Wiszniewski, A.; Szafran, J." Distance digital algorithm immune to saturation of current transformers" Fourth International Conference on Developments in Power Protection 1989.
- [30] Benmouyal, G. "Amplitude-independent comparators for UHS directional relays" Sixth International Conference on Developments in Power Protection 1997.
- [31] Bo, Z.Q.; Johns, A.T.; Aggarwal, R.K. "A new directional relay based on the measurement of fault generated current transients" Sixth International Conference on Developments in Power Protection 1997.



- [32] Yamaura, M.; Kurosawa, Y.; Ayakawa, H. "Improvement of internal charging current compensation for transmission line differential protection" Sixth International Conference on Developments in Power Protection 1997
- [33] Batty, E.R.; Thomas, D.W.P.; Christopolous, C. "A novel unit protection scheme based on superimposed currents" Sixth International Conference on Developments in Power Protection 1997
- [34] Downes, J.A.; Gwyn, B.J.; Johns, A.T.; Aggarwal, R.K.; Bo, Z.Q." Development and testing of a prototype fault generated noise protection" Sixth International Conference on Developments in Power Protection 1997.
- [35] Johns, A.T.; Bo, Z.; Aggarwal, R.K. "A novel non-unit protection scheme based on fault generated high frequency noise on transmission lines" Fifth International Conference on Developments in Power Protection 1993
- [36] Bo, Z.Q.; Li, H.Y.; Aggarwal, R.K.; Johns, A.T.; Moore, P.J. "Noncommunication protection of transmission line based on genetic evolved neural network" Sixth International Conference on Developments in Power Protection 1997
- [37] Radojevic, Z.M.; Terzija, V.V.; Djuric, N.B. "Numerical algorithm for overhead lines arcing faults detection and distance and directional protection" IEEE Transactions on Power Delivery Volume: 15, Issue: 1, Year: Jan 2000
- [38] Terzija, V.V.; Radojevic, Z.M.; Koglin, H.-J. "Novel numerical algorithm for overhead lines protection and adaptive autoreclosure" Seventh International Conference on Developments in Power Protection 2001
- [39] Dash, P.K.; Pradhan, A.K.; Panda, G.; Liew, A.C. "Adaptive relay setting for flexible AC transmission systems (FACTS)" IEEE Transactions on Power Delivery Volume: 15, Issue: 1, Year: Jan 2000
- [40] Segui, T.; Bertrand, P.; Guillot, M.; Hanchin, P.; Bastard, P. "Fundamental basis for distance relaying with parametrical estimation" IEEE Transactions on Power Delivery Volume: 15, Issue: 2, Year: Jan 2000
- [41] Bo, Z.Q.; Weller, G.; Lomas, T.; Redfern, M.A. "Positional protection of transmission systems using Global Positioning System" IEEE Transactions on Power Delivery Volume: 15, Issue: 4, Year: Jan 2000
- [42] Chen, Z.; Bo, Z.Q.; Jiang, F.; Weller, G.; "A fault generated high frequency current transients based protection scheme for series compensated lines" Power Engineering Society Winter Meeting, 2000. IEEE , Volume: 3 , 23-27 Jan. 2000
- [43] Eissa, M.M.; Malik, O.P. "A novel approach for auto-reclosing EHV/UHV transmission lines" IEEE Transactions on Power Delivery Volume: 15, Issue: 3, Year: Jan 2000
- [44] Jamali, S. "A fast adaptive digital distance protection » Seventh International Conference on Developments in Power Protection 2001
- [45] Sachdev, M.S.; Sighu, T.S.; Ghotra, D.S. "Implementation of an adaptive data window technique in a distance relay" Seventh International Conference on Developments in Power Protection 2001
- [46] Dash, P.K.; Pradhan, A.K.; Panda, G. "Application of minimal radial basis function neural network to distance protection" IEEE Transactions on Power Delivery Volume: 16, Issue: 1, Year: Jan 2001



- [47] Venkatesan, R.; Balamurugan, B. "A real-time hardware fault detector using an artificial neural network for distance protection" IEEE Transactions on Power Delivery Volume: 16, Issue: 1, Year: Jan 2001
- [48] Whei-Min Lin; Chin-Der Yang; Jia-Hong Lin; Ming-Tong Tsay. "A fault classification method by RBF neural network with OLS learning procedure" IEEE Transactions on Power Delivery Volume: 16, Issue: 4, Year: Jan 2001
- [49] Li, Y.I.; Li, B.; Zhang, X.H.; He, J.L. "An ANN-based distance protective relays of transmission lines" Seventh International Conference on Developments in Power Protection 2001.
- [50] 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.
- [51] Leitloff, V.; Bastard, P. "Novel algorithm for accelerated second zone tripping of non-unit distance protection" Seventh International Conference on Developments in Power Protection 2001.
- [52] Kim, C.H.; Kim, H.; Aggarwal, R.K.; Johns, A.T. "Wavelet transform in the accurate detection of high impedance arcing faults in high voltage transmission lines" Seventh International Conference on Developments in Power Protection 2001
- [53] Osman, A.H. Malik, O.P. "Wavelet transform approach to distance protection of transmission lines" Power Engineering Society Summer Meeting, 2001. IEEE
07/15/2001 -07/19/2001, 2001 Location: Vancouver, BC , Canada
.page(s): 115-120 vol.1
- [54] Eissa, M.M.; Masoud, M. " A novel digital distance relaying technique for transmission line protection » IEEE Transactions on Power Delivery Volume: 16, Issue: 3, Year: Jan 2001
- [55] Benmouyal, G.; Mahseredjian, J." A combined directional and faulted phase selector element based on incremental quantities" IEEE Transactions on Power Delivery Volume: 16, Issue: 4, Year: Jan 2001
- [56] Li Youyi; Dong Xinzhou; Bo, Z.Q.; Chin, N.F.; Ge Yaozhang "Adaptive reclosure using high frequency fault transients" Seventh International Conference on Developments in Power Protection 2001
- [57] Terzija, V.V.; Radojevic, Z.M.; Koglin, H.-J. "Novel numerical algorithm for overhead lines protection and adaptive autoreclosure" Seventh International Conference on Developments in Power Protection 2001
- [58] Shang, L.; Herold, G.; Jaeger, J." A new approach to high-speed protection for transmission line based on transient signal analysis using wavelets" Seventh International Conference on Developments in Power Protection 2001
- [59] Solanki, M.; Song, Y.H.; Potts, S.; Perks, A. "Transient protection of transmission line using wavelet transform" Seventh International Conference on Developments in Power Protection 2001
- [60] E. Vázquez "Application of Pattern Recognition with Principal Component Analysis for Travelling Wave Protection" IPST 2001



- [61] Hanninen, S.; Lehtonen, M “Earth fault distance computation with artificial neural network trained by neutral voltage transients” Power Engineering Society Summer Meeting, 2001. IEEE , Volume: 2 , 15-19 July 2001
- [62] Chen, Z.; Bo, Z.Q.; Jiang, F.; Weller, G.; Chin, N.F. “Boundary protection of EHV transmission lines using multi-channel frequency comparison technique” Seventh International Conference on Developments in Power Protection 2001
- [63] Redfern, M.A.; Bo, Z.Q.; Montjean, D “Detection of broken conductors using the positional protection technique” Power Engineering Society Summer Meeting, 2001. IEEE , Volume: 2 , 15-19 July 2001
- [64] Saha, M.M.; Izykowski, J.; Lukowicz, M.; Rosolowskiz, E. “Application of ANN methods for instrument transformer correction in transmission line protection” Seventh International Conference on Developments in Power Protection 2001
- [65] Yu, D.C.; Cummins, J.C.; Zhudin Wang; Hong-Jun Yoon; Kojovic, L.A. “Correction of current transformer distorted secondary currents due to saturation using artificial neural networks” IEEE Transactions on Power Delivery Volume: 16, Issue: 2, Year: Jan 2001
- [66] Micheletti, R. Pieri, R. “Walsh digital filters applied to distance protection” Instrumentation and Measurement Technology Conference, 2002. IMTC/2002. Proceedings of the 19th IEEE page(s): 487-490 Volume: 1, 2002
- [67] Jiang, J.-A.; Chih-Wen Liu; Ching-Shan Chen. “A novel adaptive PMU-based transmission-line relay-design and EMTP simulation results” IEEE Transactions on Power Delivery Volume: 17, Issue: 4, Jan 2002.
- [68] Tadeusz Lobos, J. Rezmer. “Wavelet Transforms for real time estimation of transmission line impedance under transient conditions” Electrical Engineering 84 (2002) 63-70. Springer - Verlag 2002.
- [69] Fernandez, A.L.O.; Ghonaim, N.K.I. “A novel approach using a FIRANN for fault detection and direction estimation for high-voltage transmission lines” IEEE Transactions on Power Delivery Volume: 17, Issue: 4, Jan 2002.
- [70] 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. Proceedings. PowerCon 2002. Volume: 1 , 13-17 Oct. 2002 Page(s): 300 -303 vol.1.
- [71] Huang Yizhuang; Xia Mngchao; Zhao Woquan; Liu Yinlai. “Huang Yizhuang; Xia Mngchao; Zhao Woquan; Liu Yinlai” TENCON '02. Proceedings. 2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering , Volume: 3 , 28-31 Oct. 2002
- [72] Chen, Z.; Bo, Z.Q.; Zhang, B.H.; Redfern, M.A.; Dong, X.Z.; Cauce, B.R.J.; “Developments in directional power line protection using fault transients” International Conference on Power System Technology, 2002. Proceedings. PowerCon 2002. , Volume: 1 , 13-17 Oct. 2002



- [73] Su Qianli; Dong Xinzhou; Bo, Z.Q.; Jiang, F.; « New approach of fault detection and fault phase selection based on initial current traveling waves” Power Engineering Society Summer Meeting, 2002 IEEE , Volume: 1 , 21-25 July 2002
- [74] Jiang, J.-A.; Ching-Shan Chen; Chih-Wen Liu “A new protection scheme for fault detection, direction discrimination, classification, and location in transmission lines” IEEE Transactions on Power Delivery Volume: 18, Issue: 1, Jan 2003
- [75] Jun Liang; Zhihao Yun; Feifan Liu; Yutian Liu; “A method of fault line detection in distribution systems based on wavelets” International Conference on Power System Technology, 2002. Proceedings. PowerCon 2002. Volume: 4 , 13-17 Oct. 2002
- [76] Vasilic, S.; Kezunovic, M.; “An improved neural network algorithm for classifying the transmission line faults” Power Engineering Society Winter Meeting, 2002. IEEE , Volume: 2 , 27-31 Jan. 2002
- [77] Chul-Hwan Kim; Hyun Kim; Young-Hun Ko; Sung-Hyun Byun; Aggarwal, R.K.; Johns, A.T. “A novel fault-detection technique of high-impedance arcing faults in transmission lines using the wavelet transform” IEEE Transactions on Power Delivery Volume: 17, Issue: 4, Jan 2002
- [78] Youssef, O.A.S.” New algorithm to phase selection based on wavelet transforms” IEEE Transactions on Power Delivery Volume: 17, Issue: 4, Jan 2002
- [79] Coury, D.V.; Thorp, J.S.; Hopkinson, K.M.; Birman, K.P “An agent-based current differential relay for use with a utility intranet” IEEE Transactions on Power Delivery Volume: 17, Issue: 1, Jan 2002
- [80] Chen Yanxia; Yin Xianggen; Zhang Zhe; Chen Deshu; Zeng Xiangjun; “Research on protective relaying systems based on multi-agent system” International Conference on Power System Technology, 2002. Proceedings. PowerCon 2002. Volume: 2 , 13-17 Oct. 2002.
- [81] Li Yan; Chen De-Shu; Yuan Rong-Xiang; Yin Xiang-Geri; Zhang Zhe; “Study of the transient current differential protection based on correlation analysis” Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES , Volume: 2 , 6-10 Oct. 2002
- [82] Bo, Z.Q. “Adaptive non-communication protection for power lines BO scheme 1-The delayed operation approach” IEEE Transactions on Power Delivery Volume: 17, Issue: 1, Jan 2002
- [83] Bo, Z.Q. “Adaptive non-communication protection for power lines BO scheme. II. The instant operation approach” IEEE Transactions on Power Delivery Volume: 17, Issue: 1, Jan 2002
- [84] Bo, Z.Q. “Adaptive non-communication protection for power lines BO scheme 3-The accelerated operation approach” IEEE Transactions on Power Delivery Volume: 17, Issue: 1, Jan 2002
- [85] Ha HengXu; Zhang BaoHui. “Study on identification of fault and lightning strokes in boundary protection for EHV transmission lines” Power System Technology, 2002. Proceedings. PowerCon 2002. International Conference on , Volume: 1 , 13-17 Oct. 2002



- [86] Fazio, G.; Lauropli, V.; Muzi, F.; Sacerdoti, G. "Variable-window algorithm for ultra-high-speed distance protection" IEEE Transactions on Power Delivery Volume: 18, Issue: 2, Jan 2003
- [87] Sidhu, T.S.; Ghotra, D.S.; Sachdev, M.S. "An adaptive distance relay and its performance comparison with a fixed data window distance relay" IEEE Transactions on Power Delivery Volume: 17, Issue: 3, Jan 2002
- [88] Jonsson, M.; Daalder, J.E. "An adaptive scheme to prevent undesirable distance protection operation during voltage instability" IEEE Transactions on Power Delivery Volume: 18, Issue: 4, Jan 2003
- [89] Youssef, O.A.S. "Online applications of wavelet transforms to power system relaying" IEEE Transactions on Power Delivery Volume: 18, Issue: 4, Oct 2003
- [90] Dong-Jiang Zhang; Wu, Q.H.; Bo, Z.Q.; Counce, B. "Transient positional protection of transmission lines using complex wavelets analysis" IEEE Transactions on Power Delivery Volume: 18, Issue: 3, Jan 2003
- [91] T. M. Lai¹, L.A. Snider¹ and E. Lo¹ "Wavelet Transform Based Relay Algorithm for the Detection of Stochastic High Impedance Faults" IPST 2003
- [92] X Z Dong ¹, M A Redfern ², Z Bo³ and F Jiang ⁴ "The Application of the Wavelet Transform of Travelling Wave Phenomena for Transient Based Protection" IPST 2003
- [93] Wei Chen; Malik, O.P.; Xianggen Yin; Deshu Chen; Zhe Zhang "Study of wavelet-based ultra high speed directional transmission line protection" IEEE Transactions on Power Delivery Volume: 18, Issue: 4, Jan 2003
- [94] Chi-Kong Wong; Chi-Wai Lam; Kuok-Cheong Lei; Chu-San Lei; Ying-Duo Han "Novel wavelet approach to current differential pilot relay protection" IEEE Transactions on Power Delivery Volume: 18, Issue: 1, Jan 2003
- [95] Martin, F.; Aguado, J.A. "Wavelet-based ANN approach for transmission line protection" IEEE Transactions on Power Delivery Volume: 18, Issue: 4, Jan 2003
- [96] Ernesto Vázquez-Martínez "A travelling wave distance protection using principal component analysis" Journal of Electrical Power & Energy Systems, Volume 25, Issue 6, July 2003
- [97] M. Sanaye-Pasand¹, H. Khorashadi-Zadeh² "Transmission Line Fault Detection & Phase Selection using ANN" IPST2003.
- [98] Wu, Q.H.; Zhang, J.F.; Zhang, D.J. "Ultra-high-speed directional protection of transmission lines using mathematical morphology" IEEE Transactions on Power Delivery Volume: 18, Issue: 4, Jan 2003
- [99] F. Wang and M. H. J. Bollen "Classification of component switching transients in the viewpoint of protective relays" Electric Power Systems Research, Volume 64, Issue 3, March 2003
- [100] He, H.; Cheng, S.; Zhang, Y.; Nguimbis, J. "Analysis of Reflection of Signal Transmitted in Low-Voltage Powerline With Complex Wavelet" IEEE Transactions on Power Delivery Volume: 19, Issue: 1, Jan 2004.
- [101] Zhu, T.X. "Effective Value Calculation in Wavelet Domain" IEEE Transactions on Power Delivery Volume: 19, Issue: 1, Jan 2004



- [102] Osman, A.H.; Malik, O.P “Protection of Parallel Transmission Lines Using Wavelet Transform” IEEE Transactions on Power Delivery Volume: 19, Issue: 1, Jan 2004
- [103] Dash, P.K.; Pradhan, A.K.; Panda, G. “A novel fuzzy neural network based distance relaying scheme” IEEE Transactions on Power Delivery Volume: 15, Issue: 3, Jan 2000
- [104] Kasztenny, B.; Rosolowski, E.; Lukowicz, M.; Izykowski, J.” Current related relaying algorithms immune to saturation of current transformers” Sixth International Conference on Developments in Power Protection 1997
- [105] Dong Xinzhou; Ge Yaozhong; Xu Bingyin; “Fault position relay based on current travelling waves and wavelets” Power Engineering Society Winter Meeting, 2000. IEEE , Volume: 3 , 23-27 Jan 2000 Page(s): 1997 -2004 vol.3
- [106] Chaudhary, A.K.S.; Kwa-Sur Tam; Phadke, A.G.; “Protection system representation in the Electromagnetic Transients Program” Power Delivery, IEEE Transactions on , Volume: 9 Issue: 2 , Apr 1994 Page(s): 700 -711
- [107] Nam, S.R.; Park, J.K.; Kang, Y.C.; Kim, T.H.; “A modeling method of a high impedance fault in a distribution system using two series time-varying resistances in EMTP” Power Engineering Society Summer Meeting, 2001. IEEE , Volume: 2 , 15-19 July 2001
- [108] A. M. Stankovic “Dynamic Phasors in Modeling of Arcing Faults on Overhead Lines” IPST99. International Conference on Power System Transients.
- [109] A. T. Johns, R. K. Aggarwal, and Y. H.Song “Improved techniques for modeling fault arcs on faulted EHV transmission systems,” Proc. Inst. Elect. Eng. Gener. Transm. Distr., vol. 144, no. 2, pp. 148-154, 1994
- [110] V.V. Terzija, H.J. Koglin. “ Long Arc in free Air elongation effects modeling and simulation”. European transactions on Electric Power ETEP. Vol 12. No 6, Nov/Dic 2002. pp 419 - 425
- [111] M. Kizilcay , T. Pniok “Digital Simulation of Fault Arcs in Power Systems “European transactions on Electric Power ETEP. Vol.1 No 1. Enero/Febrero 1991.
- [112] Robi Polikar. “Wavelet Tutorial”.
<http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html>. 1996
- [113] S. Mallat, W. Liang “Singularity Detection and processing with wavelets” IEEE Transactions on information theory. Vo. 38, No 2, Marzo 1992.
- [114] C. Sidney Burrus, R. A. Gonipath, H. Guo. “ Introduction to Wavelets and Wavelet Transforms”. Prentice Hall. 1998.
- [115] Y. Meyer, R. Ryan. “Wavelets – Algorithms and Applications”. Society for Industrial and applied mathematics (SIAM Press). Segunda Edición 1994.
- [116] Su Qianli; Dong Xinzhou; Bo, Z.Q.; Jiang, F.; « New approach of fault detection and fault phase selection based on initial current traveling waves” Power Engineering Society Summer Meeting, 2002 IEEE , Volume: 1 , 2002 Page(s): 393 -397
- [117] F. Jiang , Z. Q. Bo, Philip S. M. Chin “A Wavelet Transform based new directional relay using transients current signals” IPST 99. International Conference on Power System transients. Budapest. Hungria 1999



- [118] D. Chanda, N. Kishore, A. Sinha. “ A Wavelet multiresolution analysis for location of faults on transmission lines”. Electrical Power and Energy Systems, Elsevier publications. No 25. 2003. pp 59-69.
- [119] Pathirana, V.; Dirks, E.; McLaren, P.G. “Using impedance measurement to improve the reliability of traveling-wave distance protection”. Power Engineering Society General Meeting, 2003, IEEE , Volume: 3 ,Julio 2003. pp 1874-1879.
- [120] Mahanty, R.N.; Gupta, P.B.D.”_Application of RBF neural network to fault classification and location in transmission lines”. IEE Proceedings Generation, Transmission and Distribution. Volume: 151 , Issue: 2, Marzo 2004. pp. 201 - 212
- [121] 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” Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES , Volume: 2 Oct. 2002 Pages:840 - 845
- [122] Salat, R.; Osowski, S.”Accurate fault location in the power transmission line using support vector machine approach” Power Systems, IEEE Transactions on , Volume: 19 , Issue: 2 , May 2004 Pages:979 - 986
- [123] Dong Xinzhou; Chen Zheng; He Xuanzhou; Wang Kehong; Luo Chengmu. “Optimizing solution of fault location” Power Engineering Society Summer Meeting, 2002 IEEE , Volume: 3 , 21-25 July 2002 Pages:1113 - 1117 vol.3
- [124] Kawady, T.; Stenzel, J.”_Investigation of practical problems for digital fault location algorithms based on EMTP simulation” Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES , Volume: 1 , 6-10 Oct. 2002 Pages:118 - 123 vol.1
- [125] Pereira, C.E.M.; Zanetta, L.C.”_Fault Location in Transmission Lines Using One-Terminal Postfault Voltage Data” Power Delivery, IEEE Transactions on , Volume: 19 , Issue: 2 , April 2004 Pages:570 - 575
- [126] Feng Yan, Z. Chen. “ Fault Location using wavelets packets”. IEEE 2002. pp 2575 – 2579.
- [127] M. Joorabian, S. Taleghani, R. Aggarwal. “Achúrate Fault Locutor for EHV transmisión lines based on radial basis function neural networks”. Electric Power Systems Research. Publicación Futura 2004.
- [128] A. Pradhan, A. Routary. “ Wavelet Fuzzy Combined Approach for fault classification of a series compensated transmisión line”. IEEE Transaction on Power Delivery. 2004. Publicación Futura.
- [129] R. Castro, H. Díaz. “ An overview of wavelet transforms application in power systems”. 14th PSCC, Sevilla, España, Junio 2002.
- [130] P. Crossley, P McLaren. “ Distance protection based on traveling waves”. IEEE Transactions on Power Apparatus and Systems, Vol. 9. Septiembre 1983. 2971 – 2983.

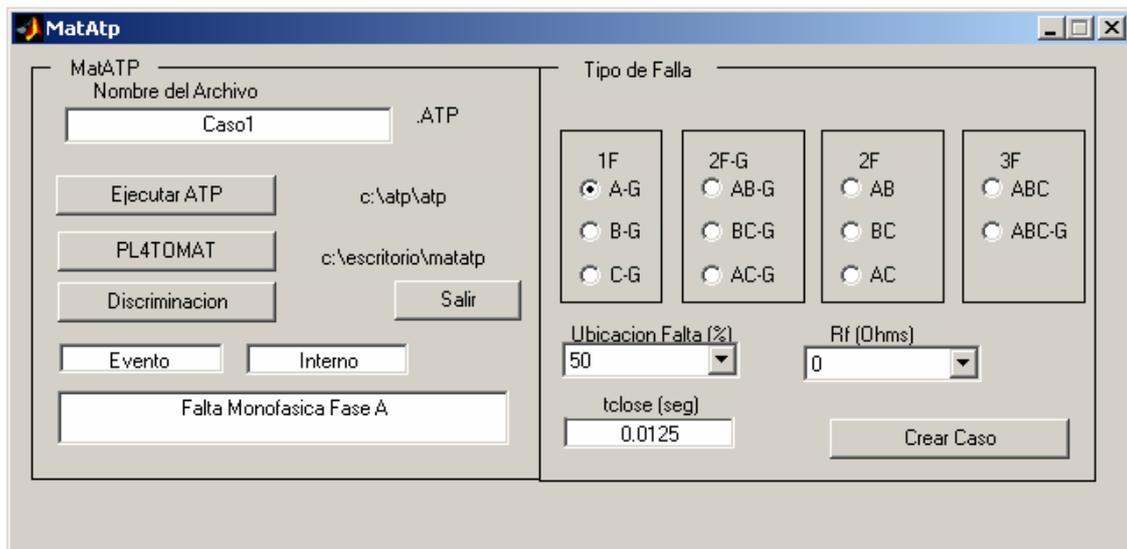


- [131] T. Kawady, Jurgen Stenzel, “ A practical fault location approach for double circuit transmission lines, using single end data”. IEEE Transactions on Power Delivery. Vol.18, No 4, Octubre 2003. 1166-1172.
- [132] A. Gopalakrishnan, M Kezunovic, S. McKenna. “ Fault Location using the distributed parameter transmission line model” IEEE Transactions on Power Delivery. Vol.15, No 4, Octubre 2000. 1169-1175.
- [133] H. Ha, B. Zhang. “ A novel principle of single ended fault location technique for EHV transmission lines”. IEEE Transactions on Power Delivery. Vol.18, No 4, Octubre 2003. 1147-1153.
- [134] L Lai, E. Vaseekar. “ Application of wavelet transform and neural networks to fault location of a feed circuit”. IEE Conference. 2000.
- [135] D. Xinzhou, G. Yaozhong. “Fault Position relay based on current traveling waves and wavelets”. IEEE PES Meeting. 2000. pp 1997 – 2003.
- [136] M. Martínez. “Protección Numérica De Líneas De Transporte De Energía Eléctrica”. Materia Tutelada: Protecciones Eléctricas. Universidad Politécnica de Madrid. 2004.
- [137] R. De Castro. “Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos”. Trabajo de Investigación. Universidad Politécnica de Madrid. España. 2002.
- [138] H. Díaz. “Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Protección diferencial del transformador con discriminación por ondículas”. Trabajo de Investigación. Universidad Politécnica de Madrid. España. 2002.
- [139] H. Yong. “Redes Neuronales”. Apuntes de clase. Universidad Simón Bolívar. 1999.
- [140] Capítulo 6. Redes Neuronales.
- [141] Neural Networks, Matsoft. Toolboxes Matlab. Versión 6p5. 2002.
- [142] K. Harish, U. Jayachandra. “Classification of power system faults using wavelet transforms and probabilistic neural networks”. IEEE Conference. 2003. pp 423 – 426.
- [143] Z. Xu, Q. Zhao. “ A novel approach to fault detection and isolation based on wavelet analysis and neural network”. IEEE Canadian Conference on Electrical & Computer Engineering. 2002. pp. 572 – 577.
- [144] Mustafa Kizilcay. “Dynamic arc modeling in EMTP”. EMTP Newsletter, Vol 5, No 3, July 1985.
- [145] W. Rogers. “Modeling of free-air arcs”. Disponible para usuarios con licencia en el website de EEUG.
- [146] M. Kizilcay. “ A survey on Numerical Modelling of Fault Arcs”. Disponible para usuarios con licencia en el website de EEUG.
- [147] T.Funabashi, H.Otoguro,L.Dubé,M.Kizilcay,A.Ametani.” A Study on fault arc and its influence on digital fault locator performance”. Conference of Developments in Power System Protection. IEE 2001. pp 418 – 421.

9.- ANEXOS

PROGRAMA PRINCIPAL MATLAB (MATATP)

Interfaz Gráfica Matlab- Atp



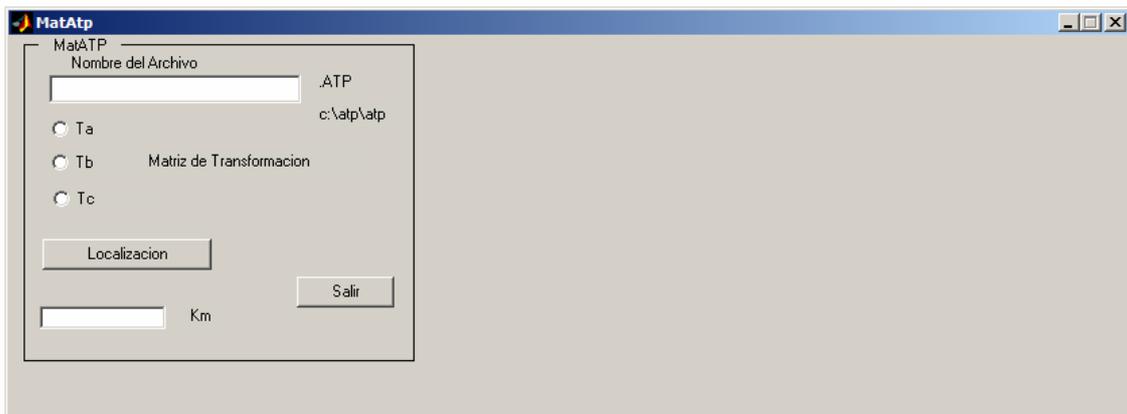
Matlab, crea la ventana (MatAtp). Apartir de ésta se genera el caso de ATP (caso ejemplo presentado en el documento) y se tiene control de variar: Tipo de Falta, su ubicación, la resistencia de falta y el tiempo de ocurrencia.

Luego se debe “Crear el Caso”, dándole previamente un nombre al archivo.

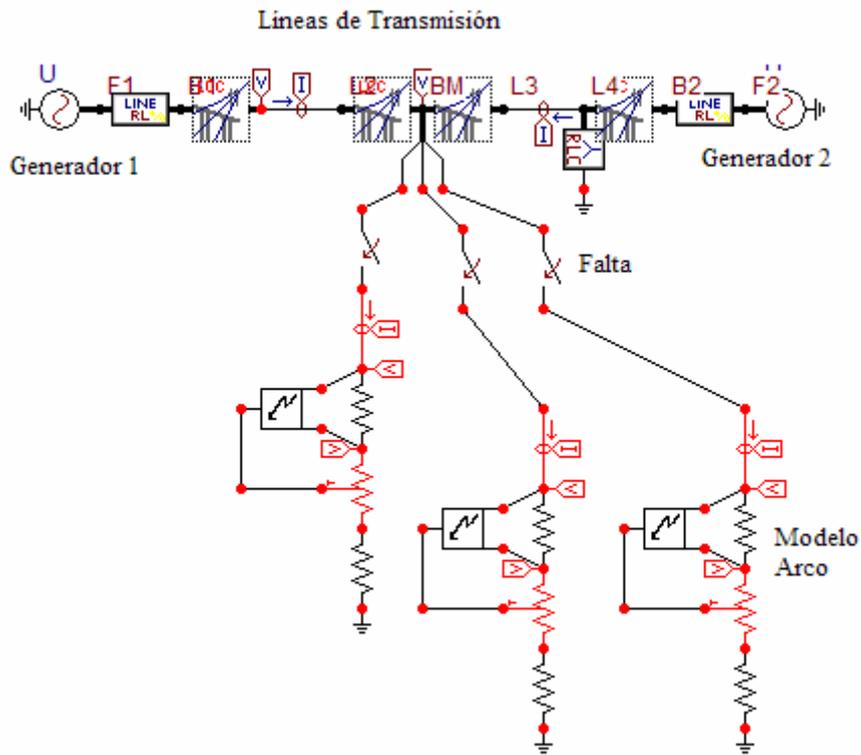
Se “ejecuta el ATP”, se transforma la información del archivo con extensión PL4 a otro con extensión mat (“PL4TOMAT”) y por último se ejecuta el algoritmo del relé, mediante la opción de “Discriminación”.



Una vez, detectada, clasificada y discriminada, se ejecuta la localización. En este caso se llama a un archivo intermedio generado por la ventana anterior.



INTERFAZ ATPDRAW PARA CASOS ESPECIALES





MODELO DEL ARCO ELECTRICO DESARROLLADO EN MODELS/ATP

MODEL Arc

comment-----

```
| Modelo para la representacion del arco      |
| primario de Falta en u aislador            |
| Input: Voltaje en R de 1mOhm de muestra     |
| Output: R TACS Tipo 91                     |
```

-----endcomment

INPUT UP, UN

OUTPUT R

DATA Uo {DFLT:9.6}, Rr {DFLT: 1.0e-3}, TAU {DFLT:8.e-4}, L {DFLT:350}

VAR gp, G, Iarc, R

HISTORY gp {dflt:1}

 G {dflt:1}

 Iarc {dflt:800}

 R {dflt:1E-8}

INIT

 R:= 1E-8

 Iarc:= 800

ENDINIT

EXEC

 Iarc:= ABS((UP-UN)/1e-3)

 G:= Iarc/((Uo+Rr*Iarc)*L)

 LAPLACE(gp/G):= (1|s0) / (1|s0 + TAU|s1)

 IF (gp<1e-10) THEN

 R:= 1E38

 ENDIF

 IF (gp>1e-10) THEN

 R:= 1/gp

 ENDIF



ENDEXEC

ENDMODEL

CREACION DE LOS CASOS A SIMULAR EN ATP, DESDE MATLAB



FUNCION MODULUS MAXIMA



FUNCION RMS



FUNCION DISTRIBUCION DE POTENCIAL



FUNCION OBTENCION DE SEÑALES EN DOMINIO MODAL



FUNCION PARA OBTENER LOS PICOS DE LOS MM



ARCHIVO COMPLEMENTARIO DEL VECTOR PARA CLASIFICACION

(Algunos casos)

3300

+1.0000	+1.0000	+0.0289	+0.0205
+1.0000	+0.0185	+1.0000	+0.0311
+1.0000	+0.0320	+0.0156	+1.0000
+1.0000	+1.0000	+0.9429	+0.0038
+1.0000	+0.0034	+1.0000	+0.9206
+1.0000	+0.9215	+0.0026	+1.0000
+0.0000	+1.0000	+0.9995	+0.0075
+0.0000	+0.0073	+1.0000	+0.9986
+0.0000	+0.9988	+0.0082	+1.0000
+0.0000	+0.9206	+1.0000	+0.9290
+1.0000	+1.0000	+0.0281	+0.0222
+1.0000	+0.0185	+1.0000	+0.0311
+1.0000	+0.0313	+0.0175	+1.0000
+1.0000	+1.0000	+0.9486	+0.0045
+1.0000	+0.0035	+1.0000	+0.9147
+1.0000	+0.9300	+0.0030	+1.0000
+0.0000	+1.0000	+0.9997	+0.0074
+0.0000	+0.0076	+1.0000	+0.9985
+0.0000	+0.9992	+0.0086	+1.0000
+0.0000	+0.9195	+1.0000	+0.8774
+1.0000	+1.0000	+0.0264	+0.0249
+1.0000	+0.0180	+1.0000	+0.0327
+1.0000	+0.0328	+0.0227	+1.0000
+1.0000	+1.0000	+0.9501	+0.0068
+1.0000	+0.0040	+1.0000	+0.8985
+1.0000	+0.9519	+0.0051	+1.0000
+0.0000	+1.0000	+0.9998	+0.0074
+0.0000	+0.0083	+1.0000	+0.9980
+0.0000	+1.0000	+0.0091	+1.0000
+0.0000	+0.9518	+1.0000	+0.8119
+1.0000	+1.0000	+0.0255	+0.0253
+1.0000	+0.0178	+1.0000	+0.0348
+1.0000	+0.0323	+0.0267	+1.0000
+1.0000	+1.0000	+0.9413	+0.0073
+1.0000	+0.0035	+1.0000	+0.8755
+1.0000	+0.9869	+0.0074	+1.0000
+0.0000	+1.0000	+0.9995	+0.0075
+0.0000	+0.0096	+1.0000	+0.9972
+0.0000	+1.0000	+0.0094	+0.9988
+0.0000	+1.0000	+0.9651	+0.7451
+1.0000	+1.0000	+0.0256	+0.0251
+1.0000	+0.0179	+1.0000	+0.0377
+1.0000	+0.0294	+0.0309	+1.0000
+1.0000	+1.0000	+0.9227	+0.0074
+1.0000	+0.0043	+1.0000	+0.8622
+1.0000	+1.0000	+0.0090	+0.9855
+0.0000	+1.0000	+0.9989	+0.0079
+0.0000	+0.0115	+1.0000	+0.9968
+0.0000	+1.0000	+0.0094	+0.9978
+0.0000	+1.0000	+0.8491	+0.6802



+1.0000	+1.0000	+0.0269	+0.0244
+1.0000	+0.0212	+1.0000	+0.0414
+1.0000	+0.0254	+0.0351	+1.0000
+1.0000	+1.0000	+0.8922	+0.0074
+1.0000	+0.0076	+1.0000	+0.8841
+1.0000	+1.0000	+0.0097	+0.9772
+0.0000	+1.0000	+0.9978	+0.0089
+0.0000	+0.0144	+1.0000	+0.9977
+0.0000	+1.0000	+0.0093	+0.9974
+0.0000	+1.0000	+0.7126	+0.6786
+1.0000	+1.0000	+0.0303	+0.0243
+1.0000	+0.0298	+1.0000	+0.0488
+1.0000	+0.0229	+0.0373	+1.0000
+1.0000	+1.0000	+0.8463	+0.0079
+1.0000	+0.0131	+1.0000	+0.9895
+1.0000	+1.0000	+0.0105	+0.9865
+0.0000	+1.0000	+0.9963	+0.0106
+0.0000	+0.0173	+0.9983	+1.0000
+0.0000	+1.0000	+0.0094	+0.9976
+0.0000	+1.0000	+0.5733	+0.7443
+1.0000	+1.0000	+0.0348	+0.0259
+1.0000	+0.0450	+1.0000	+0.0567
+1.0000	+0.0234	+0.0372	+1.0000
+1.0000	+1.0000	+0.7816	+0.0098
+1.0000	+0.0163	+0.8825	+1.0000
+1.0000	+0.9892	+0.0110	+1.0000
+0.0000	+1.0000	+0.9939	+0.0140
+0.0000	+0.0184	+0.9932	+1.0000
+0.0000	+1.0000	+0.0100	+0.9983
+0.0000	+1.0000	+0.4455	+0.8722
+1.0000	+1.0000	+0.0436	+0.0313
+1.0000	+0.0679	+1.0000	+0.0700
+1.0000	+0.0253	+0.0372	+1.0000
+1.0000	+1.0000	+0.6804	+0.0147
+1.0000	+0.0178	+0.8236	+1.0000
+1.0000	+0.9532	+0.0118	+1.0000
+0.0000	+1.0000	+0.9897	+0.0208
+0.0000	+0.0181	+0.9908	+1.0000
+0.0000	+1.0000	+0.0113	+0.9993
+0.0000	+0.9507	+0.3404	+1.0000
+1.0000	+1.0000	+0.0559	+0.0414
+1.0000	+0.0833	+1.0000	+0.0742
+1.0000	+0.0298	+0.0381	+1.0000
+1.0000	+1.0000	+0.5208	+0.0260
+1.0000	+0.0191	+0.8288	+1.0000
+1.0000	+0.9127	+0.0131	+1.0000
+0.0000	+1.0000	+0.9817	+0.0360
+0.0000	+0.0182	+0.9908	+1.0000
+0.0000	+0.9993	+0.0136	+1.0000
+0.0000	+0.7783	+0.3206	+1.0000
+1.0000	+1.0000	+0.0749	+0.0609
+1.0000	+0.0870	+1.0000	+0.0776
+1.0000	+0.0359	+0.0408	+1.0000
+1.0000	+1.0000	+0.3240	+0.0516
+1.0000	+0.0205	+0.8416	+1.0000
+1.0000	+0.8657	+0.0160	+1.0000
+0.0000	+1.0000	+0.9640	+0.0813
+0.0000	+0.0198	+0.9915	+1.0000



+0.0000	+0.9976	+0.0174	+1.0000
+0.0000	+0.6340	+0.3932	+1.0000
+1.0000	+1.0000	+0.0553	+0.0429
+1.0000	+0.0368	+1.0000	+0.0542
+1.0000	+0.0571	+0.0391	+1.0000
+1.0000	+1.0000	+0.9514	+0.0099
+1.0000	+0.0094	+1.0000	+0.9318
+1.0000	+0.9288	+0.0106	+1.0000
+0.0000	+1.0000	+0.9980	+0.0124
+0.0000	+0.0121	+1.0000	+0.9960
+0.0000	+0.9960	+0.0143	+1.0000
+0.0000	+0.8785	+1.0000	+0.8911
+1.0000	+1.0000	+0.0548	+0.0444
+1.0000	+0.0370	+1.0000	+0.0543
+1.0000	+0.0574	+0.0420	+1.0000
+1.0000	+1.0000	+0.9563	+0.0100
+1.0000	+0.0099	+1.0000	+0.9262
+1.0000	+0.9367	+0.0113	+1.0000
+0.0000	+0.9970	+0.0152	+1.0000
+0.0000	+0.0127	+1.0000	+0.9956
+0.0000	+0.9970	+0.0152	+1.0000
+0.0000	+0.8849	+1.0000	+0.8246
+1.0000	+1.0000	+0.0537	+0.0491
+1.0000	+0.0397	+1.0000	+0.0590
+1.0000	+0.0666	+0.0562	+1.0000
+1.0000	+1.0000	+0.9577	+0.0127
+1.0000	+0.0113	+1.0000	+0.9132
+1.0000	+0.9552	+0.0135	+1.0000
+0.0000	+1.0000	+0.9986	+0.0122
+0.0000	+0.0141	+1.0000	+0.9945
+0.0000	+0.9988	+0.0161	+1.0000
+0.0000	+0.9317	+1.0000	+0.7533
+1.0000	+1.0000	+0.0517	+0.0486
+1.0000	+0.0443	+1.0000	+0.0647
+1.0000	+0.0696	+0.0633	+1.0000
+1.0000	+1.0000	+0.9523	+0.0133
+1.0000	+0.0124	+1.0000	+0.8941
+1.0000	+0.9823	+0.0159	+1.0000
+0.0000	+1.0000	+0.9981	+0.0124
+0.0000	+0.0166	+1.0000	+0.9929
+0.0000	+1.0000	+0.0164	+0.9987
+0.0000	+1.0000	+0.9694	+0.6922
+1.0000	+1.0000	+0.0520	+0.0485
+1.0000	+0.0501	+1.0000	+0.0718
+1.0000	+0.0691	+0.0694	+1.0000
+1.0000	+1.0000	+0.9403	+0.0135
+1.0000	+0.0153	+1.0000	+0.8787
+1.0000	+1.0000	+0.0172	+0.9975
+0.0000	+1.0000	+0.9971	+0.0132
+0.0000	+0.0205	+1.0000	+0.9917
+0.0000	+1.0000	+0.0162	+0.9969
+0.0000	+1.0000	+0.8395	+0.6296
+1.0000	+1.0000	+0.0550	+0.0495
+1.0000	+0.0613	+1.0000	+0.0824
+1.0000	+0.0666	+0.0743	+1.0000
+1.0000	+1.0000	+0.9194	+0.0142
+1.0000	+0.0217	+1.0000	+0.8883
+1.0000	+1.0000	+0.0181	+0.9909



+0.0000	+1.0000	+0.9953	+0.0149
+0.0000	+0.0266	+1.0000	+0.9930
+0.0000	+1.0000	+0.0159	+0.9962
+0.0000	+1.0000	+0.6942	+0.6374
+1.0000	+1.0000	+0.0618	+0.0535
+1.0000	+0.0825	+1.0000	+0.1017
+1.0000	+0.0647	+0.0768	+1.0000
+1.0000	+1.0000	+0.8875	+0.0159
+1.0000	+0.0309	+1.0000	+0.9700
+1.0000	+1.0000	+0.0185	+0.9962
+0.0000	+1.0000	+0.9927	+0.0181
+0.0000	+0.0328	+0.9988	+1.0000
+0.0000	+1.0000	+0.0162	+0.9966
+0.0000	+1.0000	+0.5487	+0.7131
+1.0000	+1.0000	+0.0730	+0.0622
+1.0000	+0.1121	+1.0000	+0.1257
+1.0000	+0.0652	+0.0770	+1.0000
+1.0000	+1.0000	+0.8397	+0.0203
+1.0000	+0.0354	+0.9205	+1.0000
+1.0000	+0.9885	+0.0194	+1.0000
+0.0000	+1.0000	+0.9884	+0.0240
+0.0000	+0.0344	+0.9880	+1.0000
+0.0000	+1.0000	+0.0173	+0.9976
+0.0000	+1.0000	+0.4099	+0.8451
+1.0000	+1.0000	+0.0922	+0.0792
+1.0000	+0.1588	+1.0000	+0.1647
+1.0000	+0.0681	+0.0782	+1.0000
+1.0000	+1.0000	+0.7640	+0.0304
+1.0000	+0.0357	+0.8736	+1.0000
+1.0000	+0.9655	+0.0207	+1.0000
+0.0000	+1.0000	+0.9809	+0.0357
+0.0000	+0.0333	+0.9836	+1.0000
+0.0000	+1.0000	+0.0197	+0.9993
+0.0000	+0.9778	+0.3061	+1.0000
+1.0000	+1.0000	+0.1201	+0.1047
+1.0000	+0.1870	+1.0000	+0.1857
+1.0000	+0.0765	+0.0837	+1.0000
+1.0000	+1.0000	+0.6340	+0.0528
+1.0000	+0.0369	+0.8770	+1.0000
+1.0000	+0.9383	+0.0239	+1.0000
+0.0000	+1.0000	+0.9667	+0.0622
+0.0000	+0.0335	+0.9836	+1.0000
+0.0000	+0.9984	+0.0241	+1.0000
+0.0000	+0.7998	+0.2913	+1.0000
+1.0000	+1.0000	+0.1645	+0.1525
+1.0000	+0.1950	+1.0000	+0.1930
+1.0000	+0.0889	+0.0934	+1.0000
+1.0000	+1.0000	+0.4337	+0.1101
+1.0000	+0.0409	+0.8830	+1.0000
+1.0000	+0.9036	+0.0304	+1.0000
+0.0000	+1.0000	+0.9379	+0.1380
+0.0000	+0.0371	+0.9843	+1.0000
+0.0000	+0.9954	+0.0320	+1.0000
+0.0000	+0.6517	+0.3759	+1.0000
+1.0000	+1.0000	+0.0863	+0.0724
+1.0000	+0.0658	+1.0000	+0.0827
+1.0000	+0.0857	+0.0704	+1.0000
+1.0000	+1.0000	+0.9535	+0.0154



+1.0000	+0.0147	+1.0000	+0.9339
+1.0000	+0.9291	+0.0175	+1.0000
+0.0000	+1.0000	+0.9966	+0.0174
+0.0000	+0.0168	+1.0000	+0.9935
+0.0000	+0.9933	+0.0205	+1.0000
+0.0000	+0.8595	+1.0000	+0.8764
+1.0000	+1.0000	+0.0858	+0.0740
+1.0000	+0.0660	+1.0000	+0.0829
+1.0000	+0.0864	+0.0730	+1.0000
+1.0000	+1.0000	+0.9583	+0.0153
+1.0000	+0.0155	+1.0000	+0.9283
+1.0000	+0.9373	+0.0187	+1.0000
+0.0000	+1.0000	+0.9973	+0.0171
+0.0000	+0.0178	+1.0000	+0.9928
+0.0000	+0.9948	+0.0219	+1.0000
+0.0000	+0.8697	+1.0000	+0.8057
+1.0000	+1.0000	+0.0855	+0.0791
+1.0000	+0.0692	+1.0000	+0.0890
+1.0000	+0.0997	+0.0900	+1.0000
+1.0000	+1.0000	+0.9597	+0.0183
+1.0000	+0.0178	+1.0000	+0.9159
+1.0000	+0.9558	+0.0214	+1.0000
+0.0000	+1.0000	+0.9975	+0.0170
+0.0000	+0.0199	+1.0000	+0.9913
+0.0000	+0.9976	+0.0231	+1.0000
+0.0000	+0.9209	+1.0000	+0.7321
+1.0000	+1.0000	+0.0839	+0.0781
+1.0000	+0.0771	+1.0000	+0.0967
+1.0000	+0.1070	+0.1006	+1.0000
+1.0000	+1.0000	+0.9551	+0.0194
+1.0000	+0.0201	+1.0000	+0.8973
+1.0000	+0.9819	+0.0244	+1.0000
+0.0000	+1.0000	+0.9968	+0.0174
+0.0000	+0.0235	+1.0000	+0.9887
+0.0000	+1.0000	+0.0235	+0.9986
+0.0000	+1.0000	+0.9750	+0.6737
+1.0000	+1.0000	+0.0841	+0.0781
+1.0000	+0.0858	+1.0000	+0.1065
+1.0000	+0.1092	+0.1082	+1.0000
+1.0000	+1.0000	+0.9442	+0.0197
+1.0000	+0.0250	+1.0000	+0.8809
+1.0000	+1.0000	+0.0259	+0.9985
+0.0000	+1.0000	+0.9954	+0.0185
+0.0000	+0.0294	+1.0000	+0.9868
+0.0000	+1.0000	+0.0230	+0.9960
+0.0000	+1.0000	+0.8403	+0.6115
+1.0000	+1.0000	+0.0877	+0.0801
+1.0000	+0.1016	+1.0000	+0.1220
+1.0000	+0.1090	+0.1140	+1.0000
+1.0000	+1.0000	+0.9256	+0.0208
+1.0000	+0.0347	+1.0000	+0.8865
+1.0000	+1.0000	+0.0263	+0.9921
+0.0000	+1.0000	+0.9930	+0.0209
+0.0000	+0.0385	+1.0000	+0.9883
+0.0000	+1.0000	+0.0226	+0.9950
+0.0000	+1.0000	+0.6933	+0.6214
+1.0000	+1.0000	+0.0963	+0.0867



ARCHIVO COMPLEMENTARIO DEL VECTOR DE LOCALIZACION

(Algunos casos)

-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -40.000 +41.000 -74.000 +75.000 -119.000
-1.000 -34.000 -40.000 +75.000 +120.000 +123.000 +168.000
+1.000 -34.000 -40.000 +41.000 -74.000 +75.000 -119.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 +3.000 -34.000 -40.000 +41.000 -74.000 -118.000
-1.000 +3.000 -34.000 -40.000 +74.000 +119.000 +121.000
+1.000 +3.000 -34.000 -40.000 +41.000 -74.000 -119.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 -104.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 -104.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 -104.000
+1.000 -35.000 -36.000 -40.000 -73.000 +74.000 -116.000
-1.000 -35.000 +38.000 +41.000 +74.000 +79.000 +120.000
+1.000 -35.000 +38.000 +40.000 +41.000 -73.000 +74.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 -34.000 -36.000 -37.000 +39.000 -72.000 -73.000
+1.000 -34.000 -37.000 +41.000 +73.000 +366.000 -404.000
-1.000 -34.000 -36.000 -37.000 +39.000 +41.000 -72.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +3.000 -34.000 -35.000 -37.000 +39.000 +39.000 -41.000
+1.000 -34.000 -37.000 +41.000 +73.000 -366.000 -404.000
-1.000 -34.000 -35.000 -37.000 +39.000 +41.000 -72.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
+1.000 +3.000 +6.000 +8.000 +10.000 -34.000 -36.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
-1.000 -3.000 -6.000 -8.000 -10.000 -34.000 +37.000



+1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 -3.000 +4.000 -34.000 +36.000 -37.000 +39.000
 +1.000 -3.000 -34.000 -37.000 +41.000 +73.000 -366.000
 -1.000 -37.000 +39.000 -320.000 -367.000 -404.000 +406.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -26.000 -29.000 +30.000 -60.000 +62.000 -63.000 +65.000
 +1.000 -3.000 +5.000 -34.000 +36.000 -37.000 +41.000
 -1.000 -2.000 -3.000 -4.000 +5.000 +640.000 -642.000
 +25.000 -59.000 -61.000 -64.000 -94.000 +97.000 +128.000
 -1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +25.000 -59.000 -61.000 -64.000 -94.000 +97.000 +128.000
 +25.000 -59.000 -61.000 -64.000 -94.000 +97.000 +128.000
 +25.000 -59.000 -61.000 -64.000 -94.000 +97.000 +128.000
 +25.000 -59.000 -61.000 -64.000 -94.000 +97.000 +128.000
 -1.000 -3.000 +4.000 -34.000 +36.000 -37.000 +39.000
 +1.000 +4.000 +6.000 +8.000 +10.000 -36.000 -38.000
 +1.000 -2.000 -4.000 +6.000 -7.000 +8.000 -9.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 +34.000 +37.000 +40.000 +70.000 -73.000 -103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 -3.000 +4.000 -34.000 +36.000 -37.000 +39.000
 +1.000 +4.000 +36.000 -40.000 -44.000 -47.000 -369.000
 +1.000 -2.000 -4.000 +6.000 -7.000 +8.000 -9.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 -104.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 -3.000 +4.000 -5.000 -34.000 +36.000 -37.000
 -1.000 +4.000 +0.000 +0.000 +0.000 +0.000 +0.000
 -1.000 -3.000 +4.000 +5.000 -34.000 +36.000 -37.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 -1.000 +34.000 +37.000 +70.000 -73.000 -103.000 +104.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000
 +1.000 -34.000 -36.000 -39.000 -69.000 +72.000 +103.000