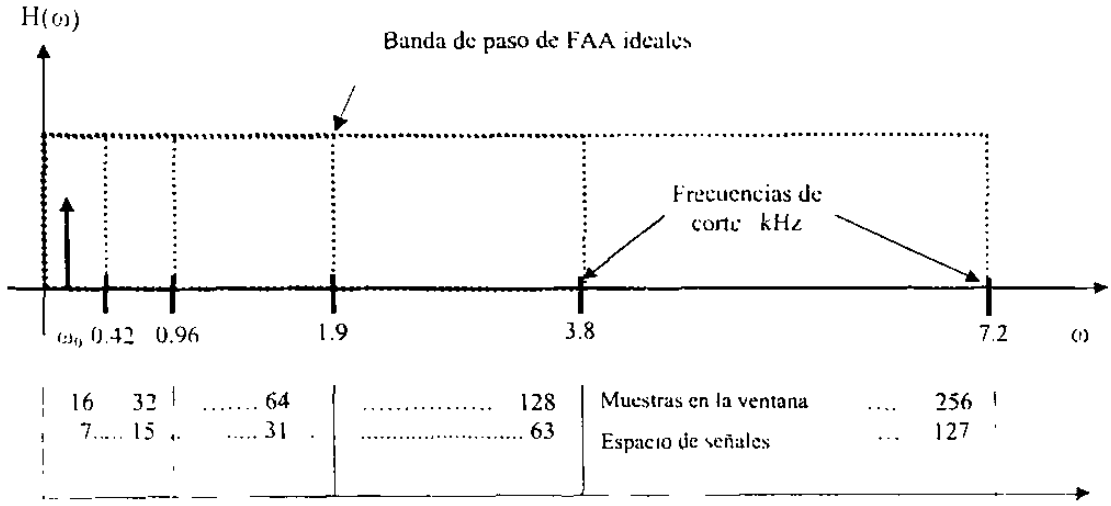

Fig. 4.2 Bandas de paso del FAA para muestreo de señales.

La Tabla 3.1 (Capítulo 3) muestra el intervalo posible de frecuencias de las señales transitorias producidas por fallas o maniobras de interruptores. La frecuencia puede superar los 20 kHz, por lo que, para introducir la información completa del proceso transitorio, el FAA debe tener una frecuencia de corte no menos de 40 kHz. Existe la limitante de que aún no es factible manejar esas frecuencias en las estructuras de los relevadores digitales actuales. En esta tesis se propone diseñar un relevador neuronal con una frecuencia de muestreo de 3840 Hz (64 muestras por ciclo) para fines de comparación se prueba también una frecuencia de muestreo de 960 Hz (ver esas alternativas en la Fig. 4.2).

En la práctica los FAA utilizados son tipos Butterworth, Chebyshev Tipo I ó II o elípticos [87]. Todos estos filtros analógicos han sido evaluados en lo referente a las componentes de frecuencia que admiten y rechazan [35]. En los procesos de reconocimiento de patrones es deseable que las armónicas contenidas en la banda de paso tengan la mínima distorsión. Los FAA de orden alto y frecuencia de corte baja tienen un retardo de tiempo elevado, lo cual se refleja en el tiempo total de operación del relevador (ver Fig. 2.5). Por ello se utilizaron filtros de orden bajo, por ejemplo, la Fig. 4.3 muestra la respuesta de filtros de cuarto orden con una frecuencia de corte de 540 Hz.

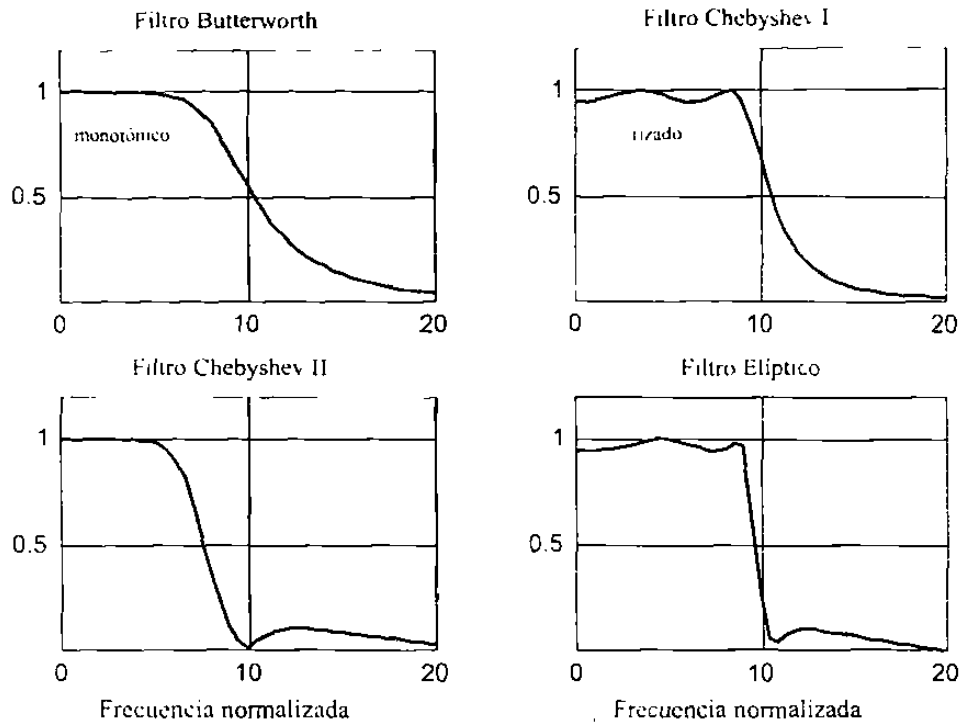

Fig. 4.3 Respuesta en la frecuencia de filtros analógicos.

La simulación de los FAA fue hecha con la utileria incluida en el programa de MATLAB [94]. Después de evaluar diferentes FAA, en este proyecto se concluyó que lo ideal para los prototipos eran los filtros Butterworth de segundo orden.

4.2.2 Conversión A/D

Una vez que pasa la señal analógica por el FAA, esta se convierte en una señal digital en el convertidor A/D. Bajo control del procesador, la señal es muestreada, y cada muestra es convertida a una palabra digital y grabada en un registro de memoria [87]. En la Fig. 4.4 se ilustra la aproximación de la señal analógica $y(t)$ mediante una serie de escalones. Del lado derecho se muestra el efecto de llenado de ventana en la memoria temporal del relevador. Con el reloj de muestreo se controlan los instantes de muestreo, separados Δt, que es el período de muestreo. En los prototipos desarrollados en esta tesis se consideran dos frecuencias de muestreo: 16 y e 64 muestras por ciclo de 60 Hz.

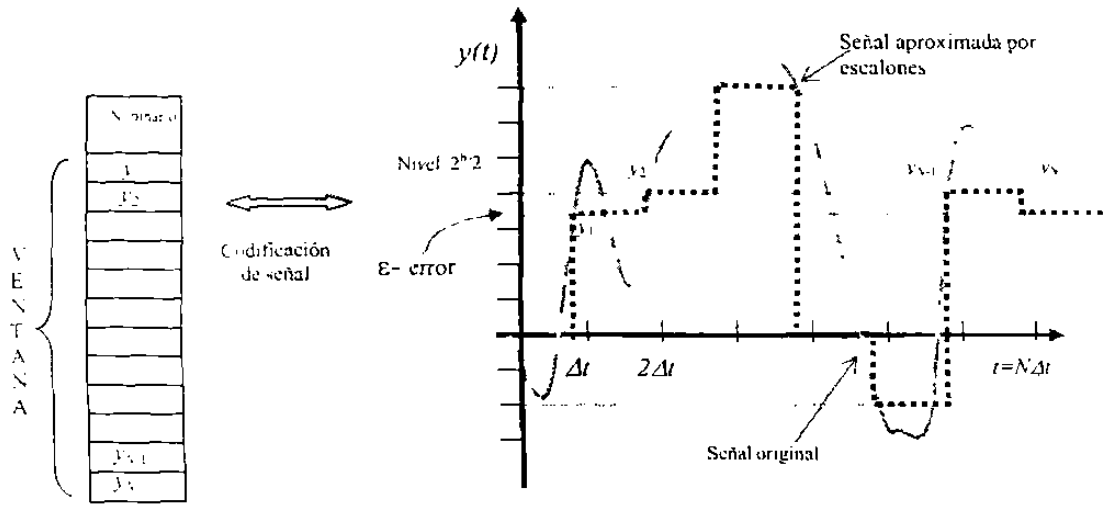

Fig. 4.4 Conversión analógo-digital con muestreo periódico.

En la Fig. 4.4 se ilustra la pérdida de información en la conversión A/D a causa de la cuantización y el muestreo. La señal codificada tiene estos dos errores. El error de cuantización ε de un registro de números codificados se determina por (4.1), y se asocia a la capacidad de resolución del convertidor A/D. Como no se puede cuantificar los valores exactos de magnitud de los pulsos de la señal discretizada, el valor de amplitud de cada pulso se codifica en un formato de número binario redondeado y/o truncado a una cantidad normalizada de bits.

$$\varepsilon = \frac{\Re}{2^b - 1} \tag{4.1}$$

donde 2^b es el número de dígitos con que se representan los valores discretos de la señal $y(k)$ y $\Re$ es el valor máximo de la señal. En los relevadores digitales se utiliza un muestreo sincrónico que da lugar al error por muestreo, que es la pérdida de la información que tiene la señal analógica y que se pierde entre muestras consecutivas [**71**] Debido a las bajas frecuencias de muestreo no es posible utilizar completamente la información generada por las OV. En el futuro será posible utilizar esa información, cuando sea posible incrementar la frecuencia de muestreo.

4.2.3 Longitud de la ventana de datos

Se ha señalado que el esquema neuronal de la Fig. 2.8 (Capítulo 2) carece de una etapa de filtrado digital. La información de interés se toma de las últimas N muestras consecutivas almacenadas en la memoria temporal del relevador. Al lado izquierdo de la Fig. 4.4 se ilustra la palabra digital que resulta de la conversión A/D y que se presenta a la entrada de las RNA.

Por otro lado, el esquema mostrado en la Fig. 2.9 tiene RNA que reciben información pre-procesada mediante el elemento extractor de rasgos distintivos. Este elemento hace las veces de un filtro digital en el sentido de que opera sobre N muestras y descubre información útil en señales contaminadas por diversos ruidos. Un problema a resolver es determinar la longitud de la ventana de datos a procesar. Para lograr una alta velocidad de operación en el relevador, la ventana de datos debe ser de menos de un ciclo de frecuencia fundamental y contener un número finito de muestras de la señal analógica $y(t)$. En este trabajo se tiene por objetivo lograr un relevador con una ventana de datos de ¼ de ciclo para lograr un tiempo de operación total de un ciclo.

En esta tesis se investiga el efecto de variar la longitud de la ventana de datos. Los artículos investigados presentan resultados satisfactorios utilizando ventanas de medio ciclo o algo menores [**32,56,89**]. Se probaron diferentes longitudes de ventana, y se estableció que la longitud de ventana debe ser no menor que el tiempo de viaje de una OV propagándose sobre el total de la longitud de la línea [**16**]. La ventana de mayor longitud ensayada en este proyecto fue la de un ciclo de frecuencia fundamental. Sin embargo, en la mayor parte de las pruebas se utilizaron ventanas de datos de longitudes iguales o cercanas a un cuarto de ciclo de frecuencia fundamental.

Una ventana de un cuarto de ciclo satisface el requerimiento de elevar significativamente la velocidad de operación del relevador neuronal con respecto a los relevadores que filtran señales para trabajar solo con componentes de frecuencia fundamental y que utilizan ventanas de un ciclo. Esto coincide con lo reportado en artículos que abordan este aspecto, con respecto al tipo de patrón a procesar por RNA [**32,57**].

4.3 Procesamiento digital de señales para esquemas neuronales

En esta tesis se investigan dos prototipos de relevador neuronal. Uno de ellos (Fig. 2.8), responde a las muestras crudas de voltaje y corriente. En el otro esquema se aplica una etapa adicional para pre-procesar la información para las RNA.

En el esquema de la Fig. 2.8, las RNA hacen las veces de filtro digital y de algoritmo de protección. Para reconocer una condición de falla, las RNA reciben una palabra digital formada de muestras crudas de cada señal de entrada y a su salida indican la operación del relevador. En la Fig. 4.5, se muestra una señal transitoria después de la conversión A/D. Se señalan tres ventanas de datos consecutivas y de longitud igual a medio ciclo. La primera ventana sólo contiene muestras del estado de prefalla; las dos ventanas subsiguientes ya ocupan posiciones en que existen muestras del estado de falla.

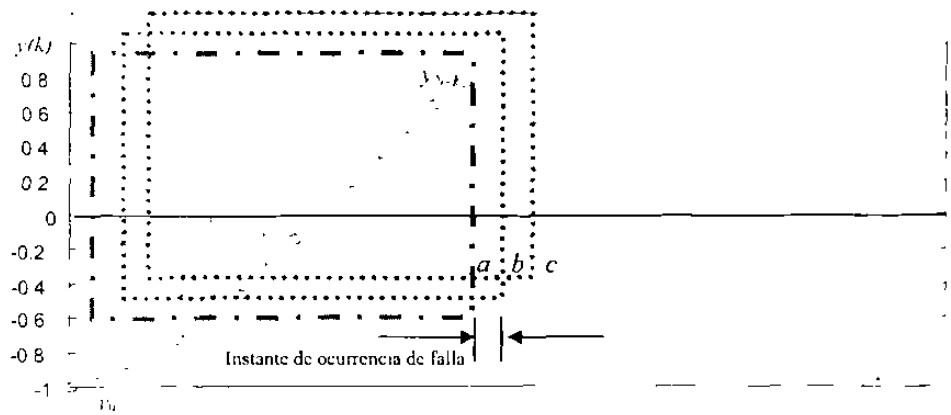

Fig. 4.5 Desplazamiento de la ventana de datos.

Los patrones representan al conocimiento que se le da a aprender a una RNA. El problema encontrado en los trabajos de protección de líneas, es que el patrón utilizado no tiene una representación única [**8,33,56,88**]. En general, los patrones se forman de agrupar las ventanas de datos de las distintas señales del SEP; solo es necesario que las ventanas de datos tengan la misma longitud, y estén capturadas en el mismo instante de muestreo.

La Fig. 4.6a muestra las ventanas que se indicaron en la Fig. 4.5 representadas como secuencias de números y con la particularidad de que se manejan desacopladas con respecto al tiempo. La palabra digital cambia cada vez que entra una nueva muestra y se desecha la muestra más antigua. Así se forman seis vectores de corrientes y voltajes (I^{abc}, V^{abc}) con un número finito de muestras de sus respectivas señales analógicas de entrada, y con distorsiones originadas por el filtrado analógico y por los ruidos de cuantización y muestreo.

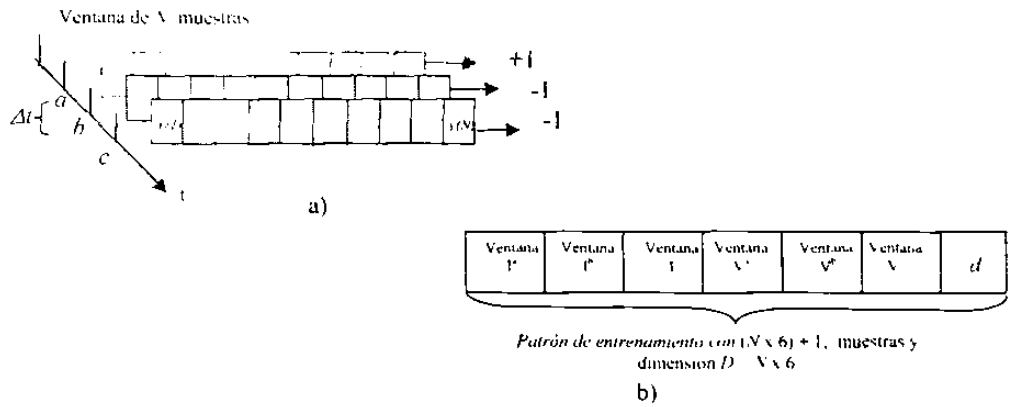

Fig. 4.6 Proceso de obtención de un patrón.

La longitud de la ventana y el número de muestras contenidas en ésta, son dos datos previamente establecidos. El patrón adquiere una forma compacta como la que se muestra en la Fig. 4.6b. En cada patrón se incluye el parámetro que indica si se trata de una falla en la zona protegida (condición de disparo +1), o cualquier otro estado del SEP (condición de no disparo -1). En la fig. 4.6, por ejemplo, la ventana *a* representa una condición de disparo, y las ventanas b y c representan casos de falla, que implican disparo.

En la literatura especializada existen trabajos que investigan el procesamiento no-lineal efectuado por las RNA **[100]**. En esta tesis se considera que la RNA realiza un mapeo de un vector de dimensión *N*, hasta un espacio de salida binaria ±1. Entonces, en el esquema de la Fig. 2.8, las RNA instauran un sistema de coordenadas para proyectar al patrón hasta el espacio de salida y de esa manera determinan la clase a la que pertenece cada patrón.

Por otro lado, el esquema neuronal mostrado en la Fig. 2.9 adiciona una etapa para realizar un filtrado digital antes de la obtención del patrón que se introduce a las RNA. Posteriormente se detallan las técnicas que se investigaron en este proyecto para generar patrones más fáciles de clasificar por las RNA. Por ahora se comentan dos limitaciones que se detectaron cuando se aplicó un filtrado digital convencional.

En [81] se ensayó la variante de aplicar un filtrado para estimación de fasores y se propuso un elemento *mho* basado en una RNA. Se utilizó un filtro de Fourier operando sobre una ventana de datos de longitud igual a un ciclo. La operación de convolución entre muestras crudas (y_N) y las funciones de Fourier (Φ) es de la forma:

$$f = y_0\phi_0 + y_1\phi_1 + \ldots\ldots\ldots y_{N-1}\phi_{N-1} \tag{4.2}$$

De esa forma se calcula el fasor de frecuencia fundamental para cada señal de voltaje y corriente. Ese procesamiento digital de señales lleva a una representación digital de dos dígitos, uno para la magnitud (M) y otro para la fase (φ):

$$f = M\angle\varphi; \quad f \in N^{n}Complejos \tag{4.3}$$

Una representación de este tipo simplificó el problema de clasificación de patrones con RNA. Cabe observar que el mapeo o proyección del patrón, es desde un espacio bidimensional, al espacio de la salida binaria ± 1, tal y como se interpreta con apoyo de la Fig. 4. 7.

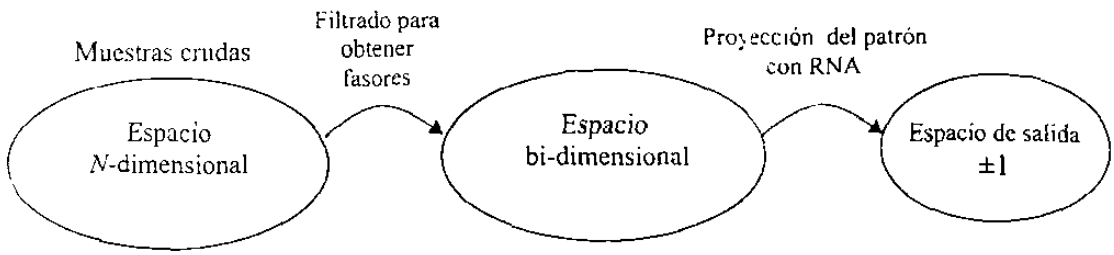

Fig. 4.7 Clasificación en esquemas neuronales que operan con fasores.

La ventaja de conocer la dimensión del espacio de señales del patrón facilita la tarea de definir la topología de las RNA, debido a que se relaciona con el número de

neuronas requeridas en la capa oculta [98]. Este estudio confirmo la limitación de la solución clásica de omitir los patrones contenidos en las componentes transitorias de alta frecuencia mediante un filtro con una ventana de datos de un ciclo.

Los resultados preliminares motivaron a diseñar un filtrado digital exclusivo para los esquemas neuronales. Se reconoció que la base de funciones de Fourier es inapropiada para hacer el filtrado requerido. Se impuso la restricción de que el filtrado genere el mínimo retardo de tiempo al relevador y que sea mínima la duración del ruido transitorio por efectos de llenado de ventana de datos con información de falla. En otras palabras, se busca un filtro de una ventana corta (idealmente, un cuarto de ciclo).

4.4 Procedimiento de generación de patrones

En la Fig. 4.8 se expone el procedimiento utilizado para obtener los patrones del entrenamiento y prueba del relevador neuronal. La primera etapa corresponde al simulador digital desarrollado y descrito en el Capítulo 3. En las siguientes etapas se normalizan las señales de corriente y voltaje internos. Se simula el filtro analógico y la conversión A/D. Posteriormente se forman los patrones, conteniendo cada uno las muestras de todas las ventanas de señales de voltaje y corriente, y el parámetro de (±1) asociado a ese patrón.

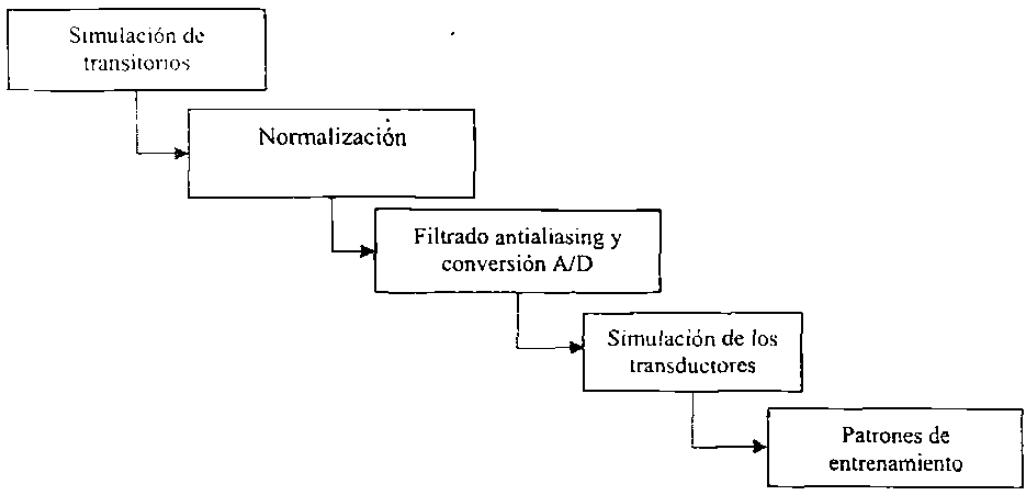

Fig. 4.8 Diagrama del proceso de generación de patrones.

En la etapa inicial del proyecto se siguió el enfoque de evaluar el efecto de introducir gradualmente ruido armónico y la componente aperiódica exponencial para formar bancos de patrones simples. Para las pruebas finales, los patrones fueron generados a partir de simulaciones detalladas de los distintos transitorios descritos en la Tabla 3.1, según el diagrama de la fig. 4.8. Las fallas y maniobras de interruptores se simulan a partir de un modelo de parámetros distribuidos con dependencia frecuencial, el cual permite reducir el paso de integración sin límite de frecuencia. Por tanto, las señales simuladas reproducen con gran precisión la información contenida en las ventanas de datos de longitud menor que un ciclo.

En diversos artículos sobre el tema se establece la necesidad de seguir un procedimiento de generación de patrones fácilmente extensible a otras configuraciones de línea. Por tanto, se estableció un criterio general para formar los bancos de patrones basado en los tres aspectos siguientes:

1. Definir una representación vectorial que asegure una invarianza en los patrones obtenidos y que asegure pertenecen a una misma clase de falla.
2. Generar un banco de patrones acotado en cuanto al número de clases y de patrones diferentes ( ).
3. Asegurar que la representación del patrón proporcione información a priori para la confeccionar la topología de la RNA.

El diagrama de la Fig. 4.8 muestra un recurso adoptado en este trabajo para reducir la variación de la representación de los patrones, que es basado en normalizar cada una de las señales de entrada. En el diseño para normalizar las señales se utiliza el valor pico de la corriente y voltaje nominales del relevador.

Los patrones de entrenamiento que se agrupan en el banco de patrones son el conjunto de ventanas de datos traslapadas en un período de tiempo de alrededor de dos ciclos, incluyendo los estados de prefalla y de falla. De esta forma, en los patrones se incluye el efecto del llenado de la ventana de datos con información de falla.

Siguiendo el procedimiento descrito, se tiene un proceso de clasificación de patrones desacoplado con respecto al tiempo. Para aplicar un entrenamiento supervisado a la RNA, es necesario asignar la categoría de pertenencia de cada patrón d_i **[2,60]**.

$$\wp = [X_i, d_i]\,|_{i=1}^{l} \tag{4.4}$$

siendo X_i un patrón formado por muestras digitales, y l es la cantidad de patrones o cardinalidad en el banco de patrones de entrenamiento o prueba, según sea la etapa de solución del proceso de reconocimiento de patrones. A continuación se presentan ejemplos de aplicación de la representación de patrones que se ensayaron en los esquemas de relevador neuronal. Primero se presenta el caso de patrones extraidos de las muestras crudas y luego se estudian distintos ERD.

4.5 Patrones de señales instantáneas

En la Fig. 4.9 se muestra un conjunto de señales de entrada al relevador ya normalizadas. Estas señales fueron generadas con el simulador digital descrito en el Capítulo 3. A estas señales se aplica posteriormente el procesamiento analogico y la conversión análogo-digital del relevador.

En la Fig. 4.9 se muestra la posición de la primera ventana de datos llena con información de falla. Se observa que en esa posición de ventana están presentes ondas viajeras y la componente aperiódica exponencial.

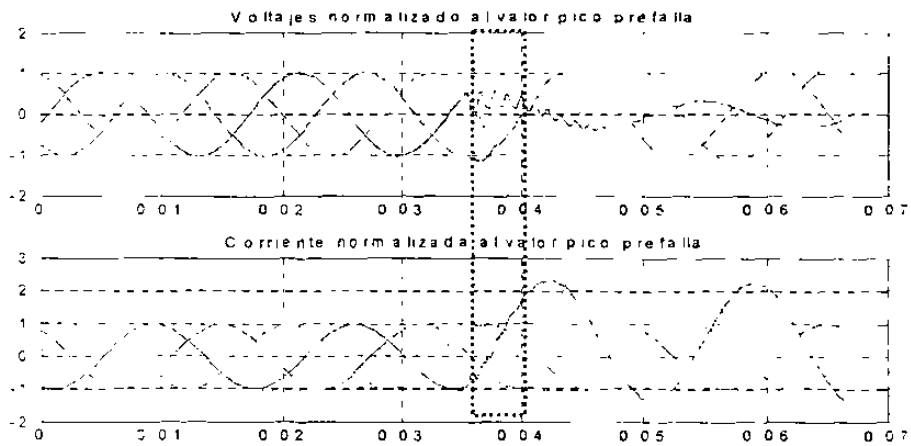

Fig. 4.9 Señales analógicas normalizadas.

La Fig. 4.10 presenta las muestras digitales después de la conversión A/D. Para obtener la señal digital, se pasaron las señales transitorias por los FAA de segundo orden

y luego se recurrió a hacer un diezmado de señales para simular el muestreo, obteniéndose valores de las muestras con dos frecuencias de muestreo, 960 Hz y 1.8 KHz (16 y 64 muestras por ciclo de 60 Hz).

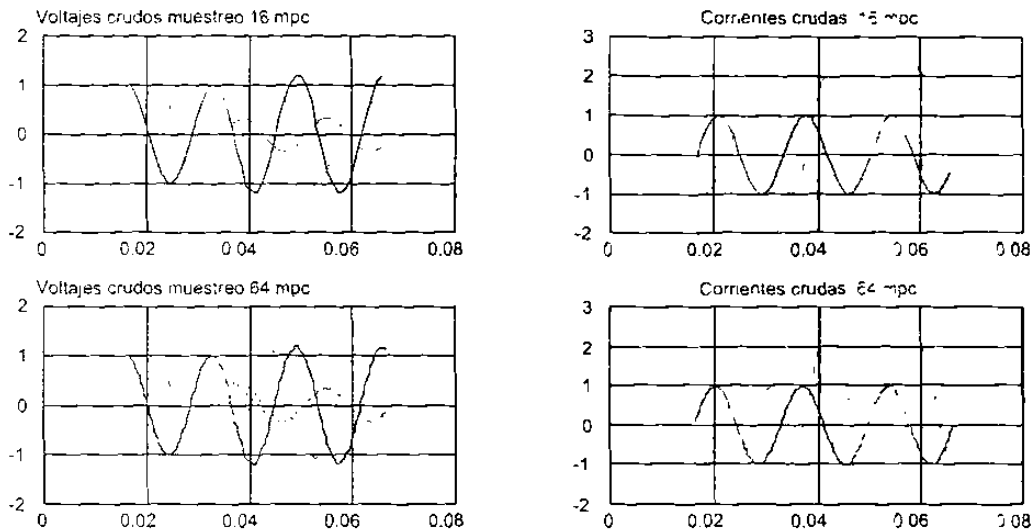

Fig. 4.10 Señales digitalizadas para relevadores de 16 y 64 muestras por ciclo

Las formas de onda mostradas en la parte superior ofrecen escasa información de alta frecuencia. Los espectros de frecuencia de los voltajes y corrientes de falla aportan información a priori de las señales transitorias. La Fig. 4.11 muestra los espectros de magnitud calculados para las ventanas de datos de un cuarto de ciclo y para las frecuencias de muestreo seleccionadas. El objetivo de estas pruebas fue observar la distribución frecuencial que se tiene en información contenida en las ventanas de datos. En base a observar esos espectros y analizar los frentes de onda, se reconocieron rasgos en el voltaje y la corriente [74].

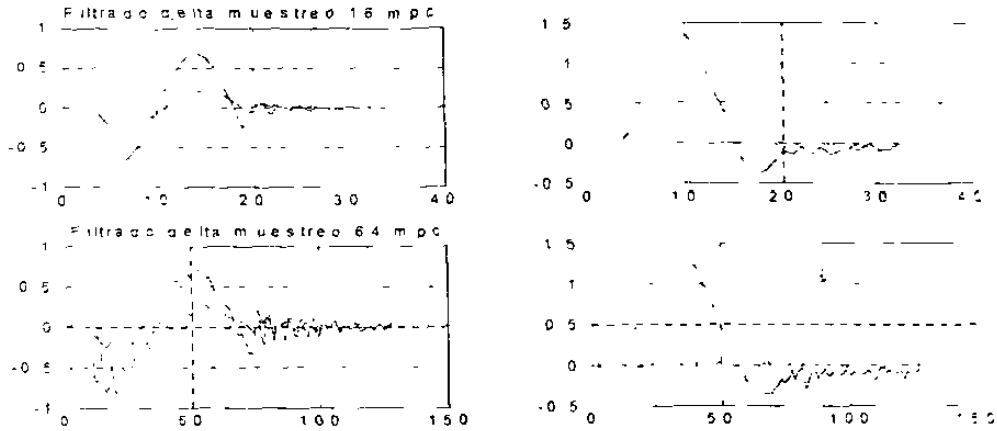

Fig. 4.14 Señales incrementales (delta) correspondiente a las señales de la Fig. 4.9

En la Fig. 4.14 se aprecia que el filtro delta produce otro estado transitorio por efectos de llenado de ventana luego de transcurrido un ciclo completo. En ese instante se agotan las muestras con información de prefalla y ocurre una segunda transición que introduce un ruido por efectos de la mezcla con información del estado de post-falla. Por tanto, las señales son válidas sólo durante un tiempo limitado.

En la Fig. 4.15 se muestra el tipo de patrón que se obtiene de agrupar ventanas de datos de cinco muestras consecutivas con solo información del estado de falla. En la parte inferior se presenta un ejemplo especial de una representación de patrón en que se ha agregado un número de muestras (ceros) del estado de prefalla. Esa es una alternativa que posteriormente se utiliza en las pruebas de desempeño de las RNA con el objetivo de suavizar el efecto de la transición del llenado de la ventana de datos.

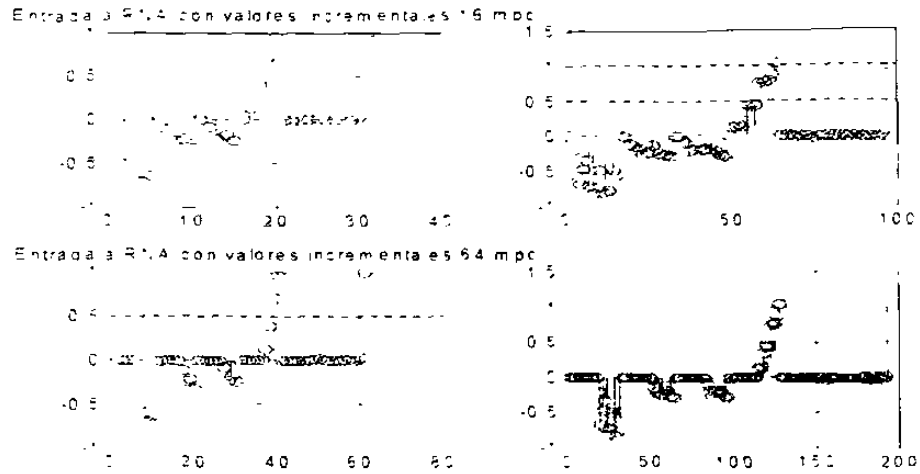

Fig. 4.15 Patron formado por ventanas de cinco muestras de 16 y 64 muestras por ciclo

Un ERD basado en un filtro delta introduce como único retardo un intervalo de muestreo (Δt). Por ello, se puede decir que esta variante responde a señales instantáneas y suprime también el tiempo de filtrado digital que se expuso en la Sección 2.4. Es decir, un esquema neuronal con un ERD delta prácticamente no tiene retraso en el procesamiento interno para la conformación de la señal lógica de disparo de interruptor. El retraso fundamental está dado en este caso por el tiempo de llenado de la ventana de datos.

4.6.2 Extractor basado en onduletas

Un ERD puede consistir en una sumatoria de convolución. Se ha explicado la limitante de calcular fasores con ventanas de longitud fraccionaria. Para esos casos es mas conveniente analizar la señal transitoria en un sistema de coordenadas N-dimensional con una base de funciones distinta a la de Fourier. En el apéndice C se resumen conceptos de representación de señales en el espacio de señales y conceptos de procesamiento de señales con onduletas.

En la literatura especializada son ampliamente descritas onduletas Daubechies, Sombrero Mexicano, Harr, etc. [**23**]. Las onduletas ofrecen un buen sistema de referencia para aquellas muestras contenidas en ventanas de datos fraccionarias. Los criterios utilizados en este trabajo para seleccionar la onduleta madre han sido los siguientes:

1. Se buscó un kernel distinto al de Fourier, que al convolucionarse con las señales crudas descubriese otra clase de rasgos en las señales.
2. Se consideraron solo aquellos kernels con un número reducido de coeficientes.
3. Se consideraron frecuencias de muestreo de 16 y 64 muestras por ciclo.

En base a estos criterios y previo al estudio de la forma de onda que resulta de solucionar las ecuaciones de línea, se propuso la onduleta Daubechies 2 como la más adecuada para descubrir rasgos representativos de la condición de falla.

Anteriormente se mostraron los espectros de frecuencia que resultan de procesar una ventana de datos de longitud menor que un ciclo fundamental. Con el algoritmo multirresolución [23], se produce un efecto de separar la señal en dos bandas de frecuencias, reduciendo así el espacio de señales en cada etapa. Esa propiedad del filtrado con onduletas permite que las RNA reciban un patrón de menor número de muestras y concentren solo rasgos contenidos en las frecuencias cercanas a la frecuencia de corte del filtro antialiasing, o solamente rasgos de baja frecuencia. Para los ejemplos con 16 y 64 muestras por ciclo, la señal digital que se procesa no contiene suficientes muestras y prácticamente en una etapa se agota la información de alta frecuencia.

La Fig. 4.16 muestra el tipo de señales que se obtienen de aplicar un filtrado con la onduleta Daubechies 2. Se han procesado solo las formas de onda de los voltajes del ejemplo de la Fig. 4.10. En la parte superior aparece la descomposición para las componentes de alta frecuencia, y en la parte de abajo la descomposición para observar las componentes de baja frecuencia. Se utilizó la utilería de MATLAB en estas simulaciones.

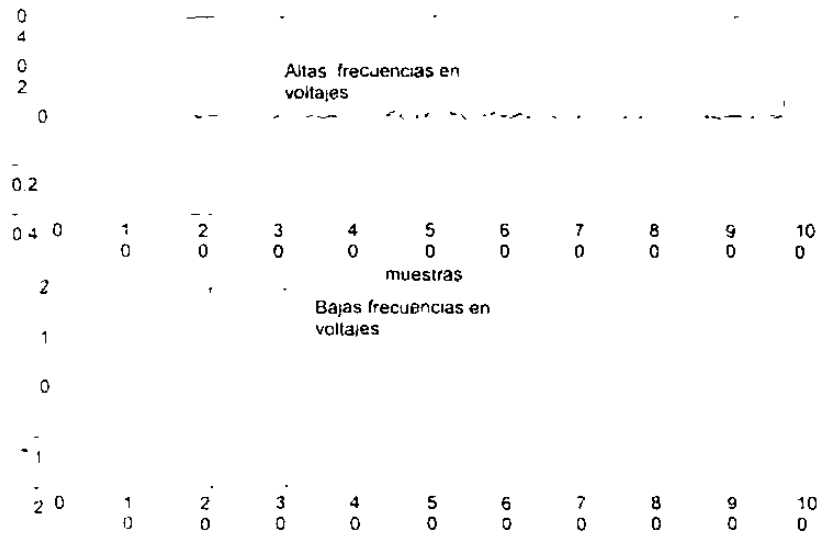

Fig. 4.16 Señal transitoria filtrada con onduleta Daubechies 2.

En la Fig. 4.17 se muestra el tipo de patrón que se forma con el ERD basado en la onduleta Daubechies 2. Se puede observar que predominan los valores de las muestras de las corrientes sobre las muestras de los voltajes.

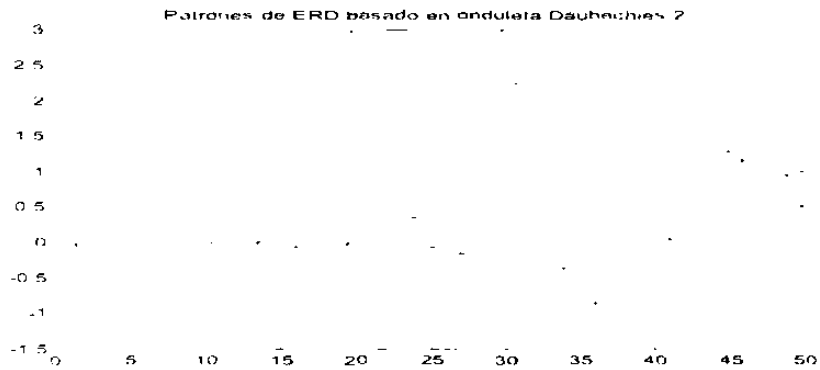

Fig. 4.17 Patrón derivado de filtrar con onduleta Daubechies 2.

4.6.3 Extractor combinado con onduletas y filtro delta

Otra variante consiste en un esquema neuronal que incluye un ERD combinado, en que primero se aplican las señales al filtro delta y ese resultado se le aplica al ERD basado en onduletas descrito en la sección anterior. El patrón que resulta para una ventana

de datos de un cuarto de ciclo con la información de falla se muestra en la Fig. 4.18. Este patrón no contiene información de prefalla y se extrae una vez que cada ventana de datos se ha convolucionado individualmente con la onduleta. El uso de esta onduleta seleccionada restringe el procesamiento a ventanas de datos con un número de muestras igual a 2^n, donde n es un número entero. Con relación al patrón mostrado en la Fig. 4.17, éste hace mas evidente la sobrecorriente de la fase fallada, que son las muestras 25 a 32, considerando que de cada señal se toman 8 muestras para formar este tipo de patrón.

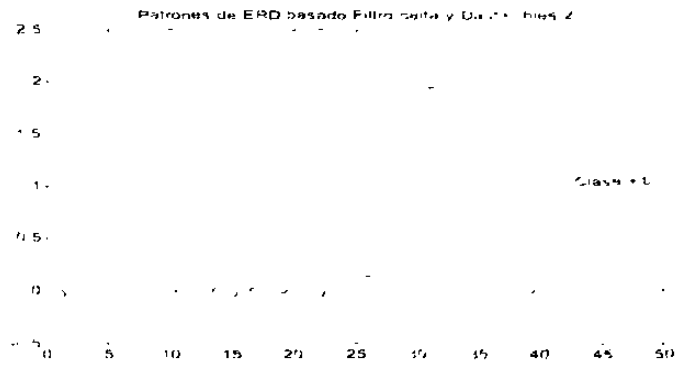

Fig. 4.18 Patron derivado de filtrar con onduleta Daubechies 2 y el filtro delta.

Con esta variante de ERD se introduce un retraso al relevador, debido al efecto de llenado de ventana, y otro por la operación de convolución con los coeficientes de la onduleta. Observe que al incluirse un ERD delta, se tiene una señal causal.

4.6.4 *Patrones de un procesamiento para fasores*

Se mencionó que se investigó también el esquema de un elemento Mho basado en RNA propuesto en un trabajo anterior [81]. Para ello hubo necesidad de procesar las señales transitorias en el simulador digital y luego hacer un procesamiento de señales como el descrito para los relevadores de distancia. En la Fig. 4.19 se muestra la información que resulta de aplicar un filtro Fourier de un ciclo.

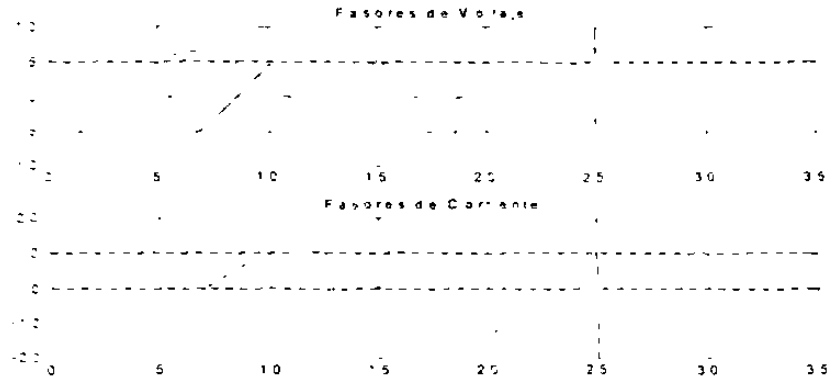

Fig. 4.19 Señales transitorias procesadas en un relevador de distancia con un filtro Fourier de un ciclo.

Otra opción de procesamiento de señales para obtener la información de frecuencia fundamental, es crear un marco de comparación de los esquemas con ERD. También se hizo el procesamiento para obtener las señales digitales producto de aplicar componentes simetricas. La Fig. 4.20 muestra las tres secuencias que se generan de la misma falla en estudio.

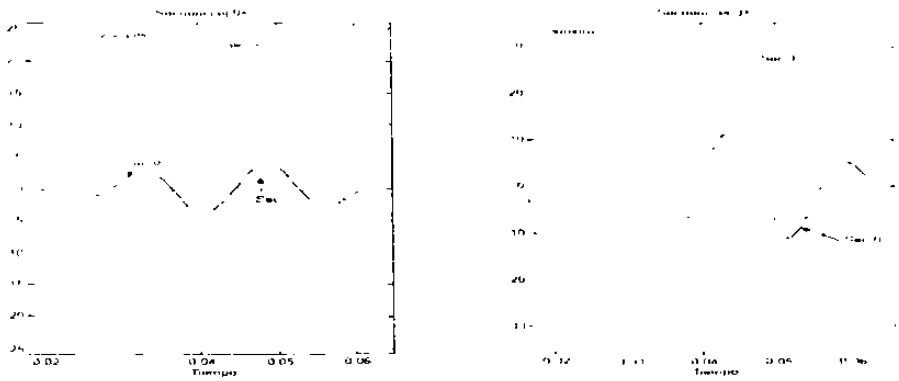

Fig. 4.20 Señales de secuencias 0+- de una condición de falla monofásica.

Otra variante que se investigó con la intención de crear un marco de comparación, es un esquema que primero tiene un procesamiento similar al anterior y, con las señales de secuencias calculadas, se calcula las impedancias como la relación voltaje entre corriente. La Fig. 4.21 muestra las formas de onda que se obtienen para la falla monofásica. Ambas alternativas extraen principalmente información de frecuencia

fundamental, pero se ven contaminados los fasores por el ruido producido por el proceso transitorio del filtro digital.

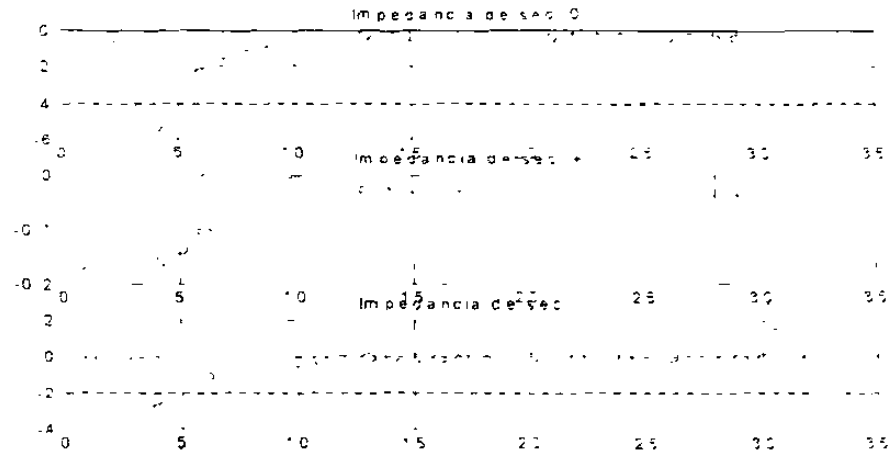

Fig. 4.21 Resistencias calculadas de la información de falla.

4.7 Formación de los bancos de patrones

Hasta ahora se han descrito las etapas para obtener la representación de patrones y se han trabajado en la confeccion de los ERD. Con ello se consuma un aspecto importante de las técnicas de IA, relativo a la presentación del conocimiento. En la etapa concerniente al diseño topológico de las RNA, se requiere de un banco de patrones para entrenamiento de las RNA. En este trabajo, se propone abordar por separado las tareas de protección de DF, CF y EZF, generando un banco de patrones para cada tarea.

Los bancos de patrones manejados, de manera intencional solo agrupan dos tipos de clases. Esto se debe a que la clasificación de una dicotomía es una representación del conocimiento consistente, para que las RNA respondan a su salida con un valor binario, sea 0 ó 1, ±1, u otro.

La Fig. 4.22 muestra las características generales de los bancos de patrones que se requiere formar para abordar las tareas básicas de protección de DF, CF y EZF en base a redes de neuronas.

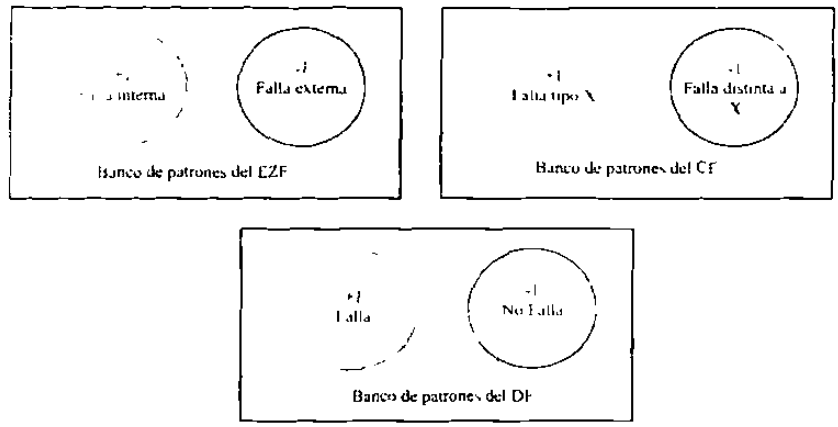

Fig. 4.22 Formación de dicotomías para los problemas de protección de líneas.

Se debe observar que los bancos de patrones son iguales en cuanto a su cardinalidad, pero las tres dicotomías indicadas tienen los patrones repartidos de manera distinta. Aunque los bancos de patrones de patrones *tienen* dos tipos de clases, para cada clase se concentra una muy diversa representatividad de fenómenos transitorios. Las fallas en lo particular se analizan con un carácter determinístico, de manera que el patron que resulta es invariable cada vez que se repitan los mismos valores para las variables aleatorias (V.A.): resistencia de falla, distancia a la falla, ángulo de inserción, tipo de falla, etc.

La combinación aleatoria de las variables da lugar a que el banco de patrones crezca en su cardinalidad. De ahí la importancia de segregar las tareas de protección y de utilizar los valores más probables en dichas variables. La Tabla 4.1 indica el intervalo dinámico de las V.A. y la correspondencia con las funciones de protección.

TABLA 4.1 CORRESPONDENCIA DE LAS VARIABLES ALEATORIAS CON LAS FUNCIONES DE PROTECCIÓN PRIMARIA

Función	Variable aleatoria (V.A.)	Intervalo
EZF	Distancia a la falla	Continuo 0-1 p.u.
CF	Tipo de falla	Discreto 1-10
DF	Resistencia de falla	Continuo 0 – R_f máxima
DF,CF EZF	Instante de ocurrencia de falla	Continuo 0 – 360°

Se debe apreciar que la única V.A. no acotada por un lado es la resistencia de falla. En la creación del banco de patrones se requiere de una condición de falla crítica para la mayor resistencia de falla. Para definir el valor de la resistencia de falla máxima se aplica un criterio práctico de utilizar 100 ohms. Con este valor se tiene una primera aproximación al estudio de la propiedad de sensibilidad del relevador neuronal.

Otra estrategia que se utiliza para reducir la cardinalidad del banco de patrones se basa en aislar el problema descrito del efecto de llenado de ventana. La transición del estado de prefalla a post-falla se investiga por separado. Por tanto, se agrupan en el banco de patrones principalmente los patrones formados de ventanas llenas con información de falla.

En la Tabla 4.1 se puede ver que de las cuatro V.A., el ángulo de inserción o instante de ocurrencia de falla incide en las tres tareas de protección. Por ello fue estudiado el efecto que produce el modificar el valor de esta V.A. particular. La Fig. 4.23 muestra las señales de una simulación en que se cambia 16 veces el ángulo de inserción de falla e intencionalmente se dejan fijos los otros valores de las otras V.A. Se han separado las señales de cada fase. La parte superior muestra las tres formas de onda del voltaje y la parte inferior muestra las tres formas de onda de las corrientes. El carácter tridimensional de la figura representa el efecto de cambiar el ángulo de inserción.

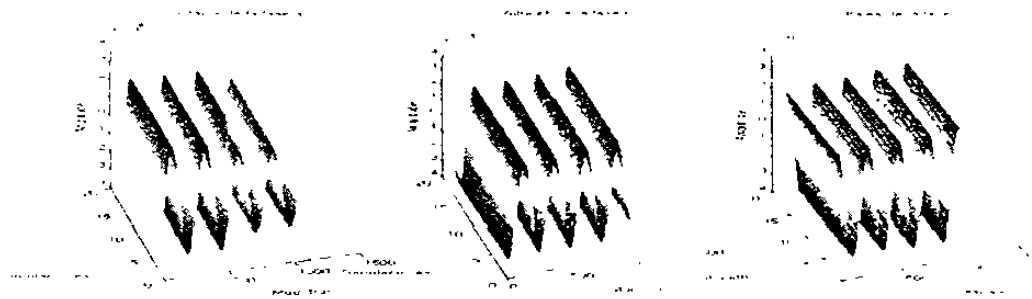

a) Formas de onda de los voltajes

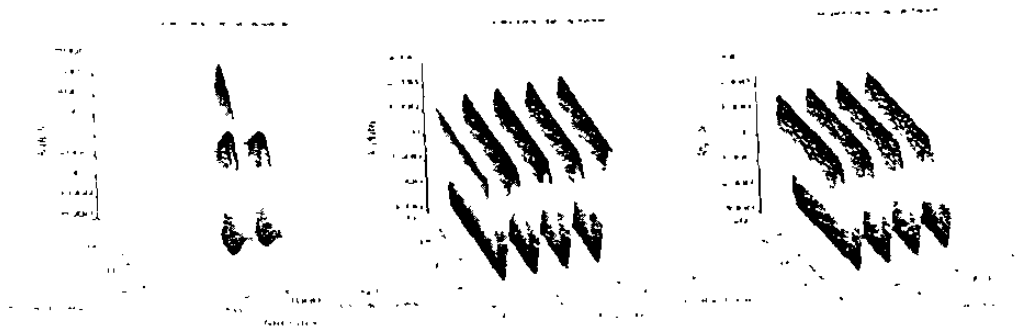

b) formas de onda de las corrientes.

Fig. 4.23 Simulación de 16 fallas en que solo cambia en ángulo de inserción de falla.

Anteriormente se mostraron ejemplos del tipo de patrón que se da a clasificar por las RNA. La Fig. 4.24 muestra la agrupación de aquellos patrones que se llevan al banco de patrones y que corresponden a la agrupación de las ventanas de datos llenas con información de falla de cada una de las 16 simulaciones que se presentan en la Fig. 4.23. Un eje del sistema tridimensional representa cada una de estas 16 simulaciones. Se indica el tipo de ERD que se considera en cada caso. Las muestras de las seis ventanas que se agrupan determinan el tamaño del patrón. Como todos estos patrones pertenecen a la misma condición de falla, se indica en el patrón un (+1). Este dato es la última muestra observada en el patrón.

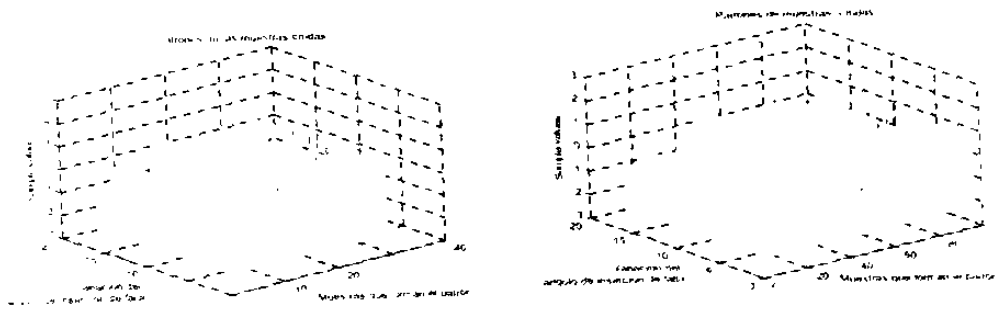

a) b)

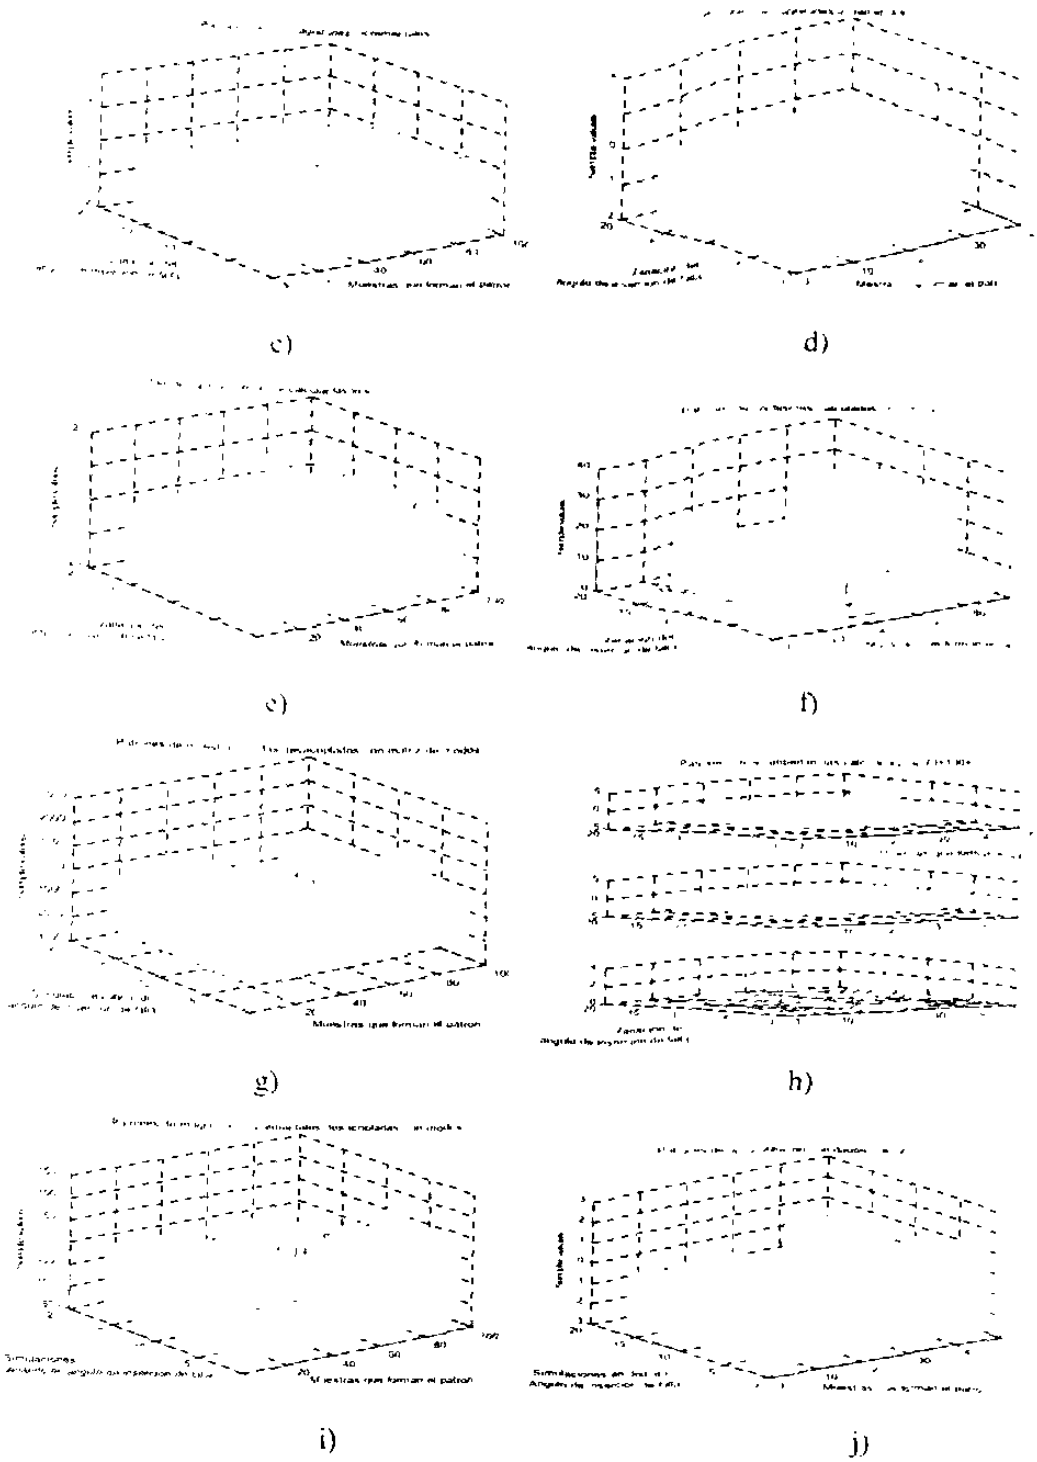

Fig. 4.24 Patrones de ventana de datos llena con información de falla de 16 simulaciones variando el ángulo de inserción de falla.

Se generaron otros grupos de patrones variando cada una de las otras V.A. y dejando fijas las restantes en cada simulación.

4.8 Conclusiones del capítulo

En este capítulo se el estudio del procesamiento de señales para un relevador digital. Se analizaron los parámetros de filtrado analógico y las frecuencias de muestreo para la conversión análogo-digital de las señales. Lo prototipos de relevador neuronal se diseñan considerado dos frecuencias de muestreo, 16 y 64 muestras por ciclo. La longitud de las ventanas de datos y el número de muestras son dos aspectos que se relacionan en el diseño de la estructura de las RNA.

Se describió el procesamiento digital de señales de un relevador neuronal. Se explicaron los pasos para obtener los patrones de entrenamiento a partir de las señales crudas. En caso que las RNA procesan muestras crudas, formadas de ventanas de datos de igual longitud, no se eliminan las componentes transitorias de alta frecuencia que deja pasar el filtro antialiasing. Esto demuestra que un relevador neuronal es capaz de reconocer condiciones de falla utilizando distinto tipo de información que los relevadores tradicionales.

Se propuso en esta tesis como un objetivo general obtener una representación de patron que resulte mas simple de clasificar por las redes de neuronas. Con ese fin se incluyó un elemento para extraer rasgos distintivos de las señales. En este capítulo se demostró con ejemplos que los ERD al operar sobre las muestras crudas producen una representación de patrón más compacta y simple de mapear. Cabe además mencionar el efecto de separar la acción de filtrado digital de la de control que se realiza en las RNA que procesan señales crudas.

En el Capítulo 3 se hizo un estudio detallado de las formas de onda de las señales en estado transitorio con el fin de reconocer dichos rasgos y aplicar un filtrado orientado a resaltarlos. En este capítulo se ha recapitulado diversas alternativas de ERD que se han probado en esta tesis con el fin de optimizar el proceso de reconocimiento de patrones con RNA. Se presentó un ERD que se basa en un filtro delta, otro basado en la convolución con la onduleta Daubechies 2, un filtro de Fourier, otro más se basa en el

desacoplamiento de señales con los modos de propagación, y se presentaron tambien ERD formados por las combinaciones de estos. Todas estas variantes son evaluadas posteriormente de manera integrada con los algoritmos de protección neuronal.

La descripción de los ERD incluye una implementación a nivel de simulación digital en MATLAB. Se utilizan las señales generadas con el simulador digital para reproducir ejemplos de de patrones a la salida del ERD. Como resultado de la aplicación de los ERD y de seguir una metodología particularmente desarrollada para formar bancos de patrones, se tiene información a priori para entrenar a las RNA.

Para diseñar las estructuras de las RNA, se ha propuesto la creación de dicotomías y la formación de los bancos de patrones manipulando V.A. con valores a priori. Estos son dos caminos que permiten manejar información poco redundante en el entrenamiento de las RNA y acelerar el proceso de solución de la clasificación de patrones.

En este capítulo también se hicieron pruebas de sensibilidad, cambiando los valores de las variables aleatorias con el fin de reconocer la información que se obtiene de los ERD considerando ventanas de longitud fraccionaria.

CAPÍTULO V

ALGORITMOS DE PROTECCIÓN NEURONAL

5.1 Introducción

El Capítulo 4 se describió la conversión de los valores instantáneos de las señales del SEP a un formato digital denominado patrón. Los patrones generados a partir de las señales crudas son procesados en el esquema de relevador neuronal de la Fig. 2.8 (Capítulo 2). Por otro lado, el esquema de la Fig. 2.9 incluye un extractor de rasgos distintivos (ERD) que opera sobre las muestras crudas y produce una representación de patrón distinta. En ambos esquemas, los patrones pasan a través de RNA y terminan clasificados en categorías que representan la solución a las tareas de detección de fallas (DF), clasificación del tipo de falla (CF) y estimación de la zona de falla (EZF). Las salidas de dichas RNA se procesan después por un módulo de conocimiento. que conforma la salida binaria de disparo de interruptor.

En el presente capítulo se seleccionan las RNA que se van a programar en un prototipo de relevador neuronal, al cual se le harán pruebas de desempeño en tiempo real en el Capítulo 6. Las pruebas realizadas en esta etapa de desarrollo se refieren a cuatro variantes de representación de patrones crudos y a 18 variantes con pre-procesamiento con ERD. Con los resultados de las pruebas se selecciona la mejor alternativa para una solución en tiempo real. Se dan a conocer los pormenores del entrenamiento y se reportan los parámetros de las RNA.

5.2 Clasificación de patrones con RNA perceptrón multicapa

El objetivo de esta fase de la investigación es determinar una estructura adecuada de RNA para clasificar en su categoría correspondiente los patrones del banco durante el entrenamiento, y los patrones que se presentan a la RNA en las pruebas de desempeño. Las RNA poseen un modelo con varios grados de libertad, que se relacionan con: a) tipo

de neurona, b) valor de *bias*, c) tipo de función de activación, d) número de neuronas por capa y e) número de capas ocultas.

Es necesario definir estos cinco parámetros, y establecer los parámetros requeridos para el entrenamiento. Una ventaja que se tiene, es que las RNA son diseñadas en un proceso estacionario, debido a que los patrones se manejan desacoplados con respecto al tiempo [60]. La estructura de la red es entonces ajustada a las restricciones impuestas por un banco de patrones ($\wp$), en el cual es conocida la clase d_i a la que pertenece cada patrón X_i.

$$\wp = [X_i, d_i]\,|_{i=1}^{l} \tag{5.1}$$

La revisión bibliográfica permitió definir algunos aspectos que facilitan la definición de los parámetros de la RNA y del entrenamiento. Por ejemplo, las RNA más apropiadas para el problema de protección de líneas de transmisión, son las de tipo perceptrón multicapa, con todas sus neuronas interconectadas y entrenadas con el algoritmo BP [58,70,88]. La Fig. 5.1 muestra una estructura típica de cuatro capas, donde en las capas ocultas se manejan N y M neuronas, respectivamente, y en la capa de salida se tiene sólo una neurona.

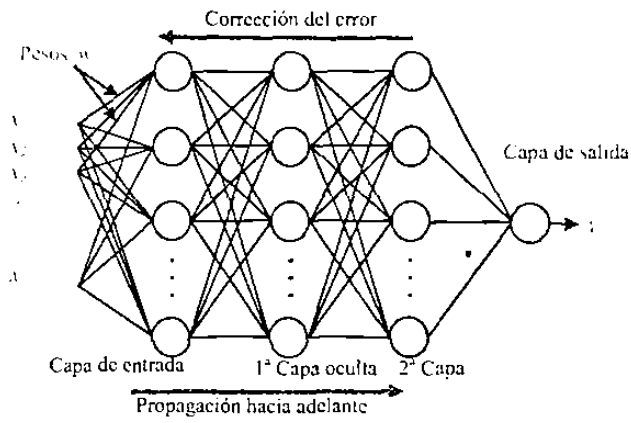

Fig. 5.1 Neurona perceptrón multicapa de cuatro capas.

Los pesos de las neuronas (w) se calculan en un proceso iterativo que se detiene cuando se minimiza una función, que por lo general representa el error promedio de los

patrones presentados en el entrenamiento supervisado [**49**]. El error resulta de la comparación directa de la propagación hacia adelante (y_i), con el valor de salida (d_i):

$$e_i(n) = d_i(n) - y_i(n) \tag{5.2}$$

En la etapa de propagación hacia adelante los pesos w conservan su valor; además, se aplica una función de activación φ a las activaciones pre-sinápticas, de la forma:

$$y_i(n) = \varphi[\ \sum_{i=1}^{m} w_{ji}(n) x_i(n)\ ] \tag{5.3}$$

En [81] se muestra que el desempeño de la RNA se eleva si se activa la neurona de la capa de salida con una función *signo* y si las neuronas de las capas previas se activan con funciones *sigmoide* o *tangente hiperbólica*. Dichas funciones le brindan el carácter no-lineal al procesamiento de las RNA y solventan el problema de redundancia de información, que por lo general existe en los bancos de patrones. En la mayoría de los casos con RNA de tres capas se logra reducir la dimensión del espacio de entrada, realizando primero un mapeo de los patrones desde un espacio de dimensión n, a otro espacio con otra dimensión, denominado espacio de los rasgos [**21**].

En la etapa de cálculo hacia atrás o de regresión, se hace la corrección del error cambiando el valor de los pesos de las neuronas de cada capa. Ese ajuste se relaciona con el gradiente local de cada *j-ésima* capa y su valor se obtiene de la derivada parcial del error global E, con respecto a los pesos [**100**]:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \tag{5.4}$$

El gradiente es un factor de sensitividad del algoritmo BP que se utiliza para determinar la dirección a seguir en el espacio de búsqueda de los pesos, para llegar al error mínimo global.

En los algoritmos implementados en la Caja de Herramienta de Neuronas Artificiales de MATLAB [**94**], se determina el error de tolerancia como la medida para detener el proceso iterativo. Un recurso adoptado en esta tesis para acelerar la convergencia de BP fue multiplicar el gradiente por un factor de valor entre 0 y 1 [**22**]. Esta alternativa hizo que en ocasiones se detuviera la solución en un mínimo local [**101**].

Por ello, posteriormente se verificó que la solución resultara en el error mínimo global antes de pasar a las pruebas de desempeño y de generalización con patrones no presentados durante el entrenamiento de la RNA [**98**]. En [**45**] se demuestra que sobredimensionar la estructura de RNA origina una mala generalización, por lo que es recomendable adoptar estructuras compactas.

Existen ocasiones en que el algoritmo BP no converge, pero repitiendo el entrenamiento a la misma estructura se puede obtener una solución. Sin embargo, ese resultado es indicativo de que el proceso exige otra topología, ya sea de mayor número de capas ocultas, de mayor número de neuronas por capa, o ambas cosas. Se puede también cambiar el tipo de funciones de activación, el orden de la presentación de patrones de entrenamiento, y el *bias*.

Está reportado en [**55**] que con el algoritmo BP el mejor grado de clasificación esperado es de un 80%. Se ha concluido que el desempeño de BP depende en gran medida de la correcta representación del conocimiento, dada con los patrones. Este aspecto fue relevante para este trabajo, y por ello se trató de no dar una relación entrada-salida $[X_i, d_i]$ ambigua.

Es importante mencionar que la definición del número de capas ocultas y del número de neuronas en las capas ocultas es un área de investigación que ha venido encontrando soluciones mediante la aplicación de las técnicas de regularización [**22**]. El recurso adoptado en esta tesis para reducir el grado de heurística del diseño de RNA, fue utilizar información a priori en la formulación convencional de BP y aplicar la metodología desarrollada con ese propósito. También se propuso incluir al ERD en el esquema del relevador. A continuación se reportan los resultados alcanzados en este trabajo cuando se utilizan RNA tipo perceptrón multicapa, entrenadas con BP y con datos de entrada obtenidos de muy diversas condiciones operativas del sistema de potencia, incluyendo fallas y otros fenómenos transitorios.

5.3 Metodología de diseño de las estructuras de RNA

Los parámetros que se definieron para las RNA comparadas en las pruebas de clasificación de patrones son los siguientes: a) Se utilizó la tangente hiperbólica como

función de activación. b) La capa de salida consta de una sola neurona y se activa con una función signo. c) Las RNA tienen +1 y -1 como valores de salida, debido a que se demostró previamente que era la opción más discriminativa [**8**,**32**]. d) En la mayoría de los casos, la capa de entrada tiene un número de neuronas igual a la dimensión de las señales de entrada; por ejemplo, si la señal digitalizada es de 16 muestras por ciclo, el número de neuronas de la capa de entrada es 7 (o sea, $n/2$ -1); esto se muestra en la Fig. 4.2.

El número de capas ocultas y el número de neuronas de cada capa de una RNA multicapa se determinaron utilizando la metodología que se describe a continuación:

1. Se comienza con una topología de una sola capa oculta y con un número elevado de neuronas. Se entrena la RNA con el algoritmo BP que utilizan las técnicas de regularización, disponible en MATLAB [**98**]. Esto permite detectar y descartar aquellas neuronas cuyos pesos son de valor tan bajo, que prácticamente no contribuyen al funcionamiento de la RNA [**22**]. Se determina así el número N de neuronas útiles en la red. Se utiliza una tolerancia de error poco exigente para garantizar resultados rápidos. En esta etapa se utilizó el valor de 0.1 para el error.

2. Se entrena una RNA de una sola capa oculta con N neuronas utilizando el algoritmo BP de Levemberg-Marquard, que asegura convergencia en un mínimo global. Se toma 0.001 como tolerancia del error, o en su defecto se hace un máximo de 1000 iteraciones.

3. Se hacen pruebas de desempeño a la RNA de una sola capa con N neuronas. Se utilizan primero algunos de los patrones de entrenamiento (prueba de clasificación). Posteriormente, se aplican patrones diferentes a los utilizados durante el entrenamiento, para evaluar la capacidad de generalización. Si los resultados son positivos, esta es la estructura adecuada.

4. Si la red de una capa con N neuronas no tiene un buen desempeño, se entrenan y prueban redes con números de neuronas cercanos a N. Si alguna de estas RNA generaliza bien, se adopta esa estructura.

5. Si ninguna RNA de una capa tiene buena capacidad de generalización, se pasa a una estructura de dos capas. Se entrena una RNA con dos capas ocultas,

utilizando números altos de neuronas en ambas capas ocultas, y aplicando el algoritmo de regularización. Así se determinan los números N y M de neuronas que son útiles en ambas capas.

6. Se entrena una RNA con dos capas ocultas de N y M neuronas respectivamente, utilizando el algoritmo de Levemberg-Marquard [**61**]. La tolerancia de error se hace más exigente que en el Paso 5.

7. Se hacen pruebas de desempeño a la RNA con N neuronas en la primera capa y M en la segunda capa. Si la capacidad de generalización es buena, se adopta esta estructura.

8. Cuando la red no tiene buen desempeño, se entrenan y prueban redes con números de neuronas cercanos a N y M en ambas capas, hasta encontrar la RNA que tenga buena capacidad de generalización.

9. Si ninguna RNA de dos capas ocultas tiene buena capacidad de generalización, se pasa a una estructura de tres capas ocultas y se repiten los pasos del 5 al 8. Este proceso puede repetirse con más de tres capas ocultas si es necesario.

Para la función de protección de líneas en este trabajo se probaron RNA con una y dos capas ocultas y con diferentes números de neuronas en cada capa; los números concretos de capas y de neuronas por capa de las RNA dedicadas a las tareas de DF, CF o EZF, se dan a conocer en las tablas incluidas a este capítulo.

5.4 Detector neuronal de fallas (DF)

Los relevadores de protección digital de líneas utilizan un algoritmo dedicado exclusivamente a la tarea de detección de fallas. Este algoritmo activa el relevador en sus funciones de protección e inicia el procesamiento. Por tanto, este algoritmo debe ser muy rápido y, al mismo tiempo, ser lo suficientemente sensible como para detectar todas las fallas posibles en el elemento protegido [**1**].

En los relevadores digitales tradicionales se han utilizado diversos algoritmos determinísticos de detección de fallas. Se han propuesto detectores neuronales de fallas que procesan la información de cada fase por separado [**8,9**]. Se requiere una RNA por

fase al menos. En esta sección se resume la investigación realizada en esta tesis para tratar de crear un detector neuronal de fallas trifásico, compuesto por una sola RNA que procese información de todas las fases simultáneamente.

En el esquema de relevador neuronal propuesto en esta tesis se utiliza un DF neuronal para detectar la ocurrencia de una falla. Dado el requerimiento de velocidad de operación, se propuso utilizar estructuras de RNA que responden a patrones creados a partir de ventanas de datos de longitud menor que un ciclo.

Como resultado de las simulaciones digitales de fenómenos transitorios, se obtuvieron los patrones a ser utilizados en los procesos de entrenamiento y prueba de las RNA. Los patrones de entrenamiento para cada caso consisten en un conjunto de ventanas de datos traslapadas en un período de tiempo que abarca cuatro ciclos de frecuencia fundamental, incluyendo toda la transición de prefalla a post-falla. Los patrones del banco del elemento DF se dividen en las dos clases siguientes (ver Fig. 4.22):

1. Un grupo representa la clase de falla, que incluye fallas en cualquier zona y todo tipo de fallas. Este grupo se asocia con la salida +1 de la RNA. Está formado por unos 122,000 vectores (cada vector corresponde a una ventana de datos), generados de 2,100 fallas distintas. En las simulaciones se considera la combinación de 10 distintos puntos de falla, 15 valores de resistencia de falla y 32 instantes de ocurrencia de cada falla.

2. El otro grupo es la clase de no falla, que se asocia con la salida –1 de la RNA. Está formado por unos 64,000 vectores, generados de 155 operaciones de cierre de interruptores y 155 operaciones de apertura. También se incluyen en este grupo 120 patrones de dos oscilaciones de potencia estables, 750 patrones de dos oscilaciones inestables, y 600 patrones correspondientes a estados normales de carga.

De los aproximadamente 184,000 vectores generados para el banco de patrones del DF, se utilizó la mitad (vectores pares) para el entrenamiento de las RNA y la otra mitad (vectores impares) para las pruebas. Es importante aclarar que para las otras tareas de protección se utilizan bancos de patrones con otras características. En la literatura

especializada no se dispone de una base de datos con esa riqueza de información; esta base de datos es una de las contribuciones originales de este trabajo.

5.4.1 Diseño de prototipos de DF neuronales

A continuación se explica con ejemplos la manera en que se diseñaron los DF aplicando BP. Se presentan los resultados de entrenar cuatro DF. Estas pruebas sirven para visualizar el efecto de incluir en el esquema el ERD y el efecto de aumentar la frecuencia de muestreo de 16 a 64 muestras por ciclo.

Se aplicó la metodología descrita en la Sección 5.3 para definir la estructura de RNA más adecuada del DF. Para las estructuras de una sola capa oculta, se comenzó con 15 neuronas y el algoritmo de regularización permitió definir N=9 como un número de neuronas adecuado. A continuación se probaron RNA con N=5, 6, 7, 8, 9 y 10, entrenadas con Levemberg-Marquard.

La Fig. 5.2 muestra los resultados del entrenamiento y pruebas del DF neuronal, que fue realizado con patrones creados a partir de cinco muestras crudas (no pre-procesadas) consecutivas [32]. Las señales digitales contienen 16 muestras por ciclo. Los resultados mostrados a continuación corresponden a un entrenamiento en una estructura de 6, 7 y 1 neuronas respectivamente, y con los parámetros dados a conocer anteriormente. La Fig. 5.2a muestra el error de la RNA como función del número de iteraciones. La línea horizontal simboliza el valor de tolerancia establecido, igual a un error de 0.001. La Fig. 5.2b muestra el resultado de clasificar algunos patrones utilizados durante el entrenamiento, y la Fig. 5.2c muestra los resultados de clasificar patrones no utilizados en el entrenamiento de este DF. Esta es la denominada prueba de generalización de la RNA. En condiciones ideales, la RNA debe dar una salida +1 para fallas, y una salida -1 para casos de no falla. En realidad cada salida es un número comprendido entre +1 y -1. Se utiliza entonces un filtro para procesar la información de salida de la RNA. Ese filtro, en el caso de esta tesis, consiste en considerar +1 toda salida y de la RNA que cumple con el criterio $y \geq 0$. Se considera -1 toda $y < 0$.

(a) Convergencia de la RNA (b) Prueba de clasificación (c) Prueba de generalización

Fig. 5.2 Entrenamiento y pruebas de un DF con patrones crudos y con una RNA de una capa oculta (16 muestras por ciclo).

Se observa que, cuando se clasificaron patrones crudos, el algoritmo BP hizo 1000 iteraciones sin alcanzar la congruencia, para una tolerancia de error de 0.0001. En cada iteración se aplicaron a la RNA cerca de 85,000 patrones distintos. Con ese gran volumen de información y ese criterio de parada, el tiempo de convergencia fue de 4 horas y 16 minutos, con una computadora personal con 512 MB de RAM y un microprocesador Pentium 4 de 2.4 GHz.

La Fig. 5.2b representa la clasificación de 1000 patrones que habían sido utilizados para entrenamiento. Se colocaron al inicio 300 patrones de una clase, seguidos de 700 patrones de la otra clase. Aunque no se llegó a la tolerancia de error, se observa que la clasificación de patrones utilizados en el entrenamiento es aceptable. Por otro lado, En la Fig. 5.2c se observa el resultado de clasificar 1000 patrones que no fueron utilizados durante el entrenamiento. Con esa prueba se confirmó la baja capacidad de generalización de las RNA de una capa oculta, cuando se hace la clasificación de patrones crudos [32,57,88].

La Fig. 5.3 muestra resultados de un DF neuronal que pre-procesa la información con un ERD Delta (Δ). Con fines de comparación entre ambos DF, se entrenó la RNA con los mismos parámetros y la misma estructura de 6, 7 y 1 neuronas respectivamente.

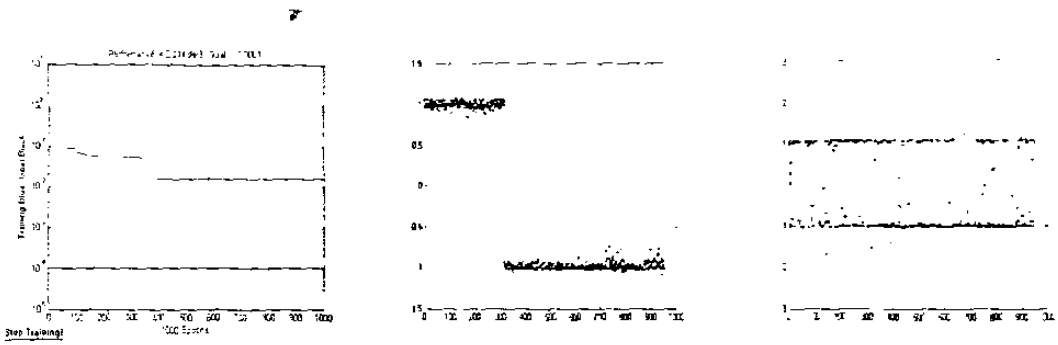

(a) Convergencia de la RNA (b) Prueba de clasificación (c) Prueba de generalización

Fig. 5.3 Entrenamiento y pruebas de un DF con patrones Delta y con una RNA de una capa oculta (16 muestras por ciclo).

Se observa en la Fig. 5.3a que con esta estructura tampoco se alcanzó la tolerancia de error en el entrenamiento. La clasificación de los patrones presentados durante el entrenamiento (Fig. 5.3b) superó los resultados de la prueba anterior. Sin embargo, se puede observar en la Fig. 53c que los resultados de las pruebas de generalización (patrones nuevos) son malos. De la comparación de estas dos variantes de DF neuronales, se puede concluir que el ERD Delta eleva la calidad de la clasificación, y además reduce el tiempo de entrenamiento (2 horas y 41 minutos), pero no constituye una solución aceptable.

Se investigó también el efecto que produce el aumento de la frecuencia de muestreo. La Fig. 5.4 muestra los resultados de entrenar una RNA con 16, 10 y 1 neuronas, respectivamente, con una frecuencia de muestreo de 64 muestras por ciclo. Los patrones son distintos a los de las pruebas anteriores, porque se forman de agrupar seis ventanas, cada una con 16 muestras. Esa representación cuadruplica el número de muestras en la ventana de datos, pero conserva la longitud de un cuarto de ciclo. La Fig. 4.15 muestra el tipo de patrones utilizados para esta prueba.

En esta tercera prueba, el algoritmo BP hizo 53 iteraciones y llegó al error mínimo global de 0.0001. Aunque se manejó doble volumen de información, el entrenamiento de esa estructura logró superar la prueba de convergencia. El entrenamiento duró aproximadamente 39 minutos, en la misma computadora.

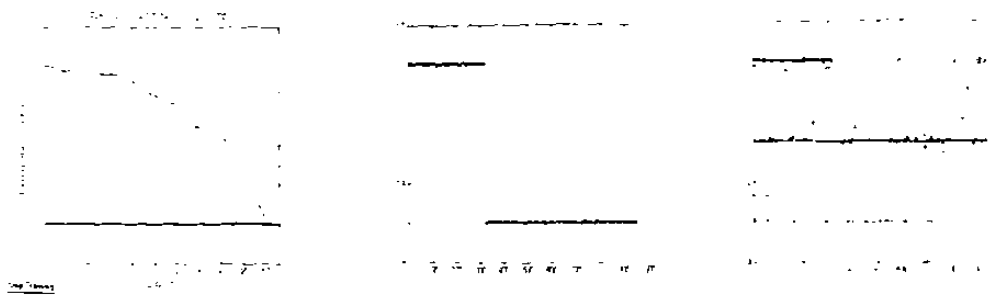

(a) Convergencia de la RNA (b) Prueba de clasificación (c) Prueba de generalización

Fig. 5.4 Entrenamiento y pruebas de un DF neuronal con patrones Delta y con una RNA de una capa oculta (64 muestras por ciclo).

Se utilizaron 1000 patrones del banco de patrones de entrenamiento para efectuar las pruebas de desempeño a esta RNA de una capa oculta. La Fig. 5.4b revela la excelente clasificación que se logra para los patrones utilizados en las pruebas. Un resultado similar se presentó siempre que el algoritmo BP convergió con la tolerancia de error establecida. Sin embargo, en la Fig. 5.5c se puede observar que esa estructura no supera las pruebas de generalización, en que se utilizan patrones diferentes a los de entrenamiento.

El resultado anterior permitió concluir que dar más información del estado transitorio a la RNA (utilizando una mayor frecuencia de muestreo) es una vía para mejorar la calidad de la clasificación. Un problema detectado es que se complicó en forma considerable el manejo de los bancos de patrones, al punto de que en varias pruebas se agotó la capacidad de memoria disponible en la computadora para el entrenamiento. En esos casos no se obtuvo una solución por causa de una insuficiente capacidad de cómputo.

Los resultados de las pruebas anteriores, y de otras pruebas similares realizadas, permitieron concluir que las RNA de una sola capa tienen problemas de convergencia, y que en general no son estructuras apropiadas para la tarea de DF.

Se pasó entonces a investigar estructuras de dos capas ocultas. Se repitió el proceso, partiendo de una estructura con 15 neuronas en cada capa, y el algoritmo de regularización permitió definir N=7 y M= 5 como números de neuronas adecuados. Se entrenaron con Levemberg-Marquard y se probaron RNA con N= 14, 15 y 16, y cada una de ellas con M=7, 8, 9. La Fig. 5.5a muestra los resultados de entrenar una estructura de

10, 7, 5 y 1 neuronas, respectivamente, utilizándose los mismos patrones Delta del ejemplo en que la frecuencia de muestreo es de 16 muestras por ciclo.

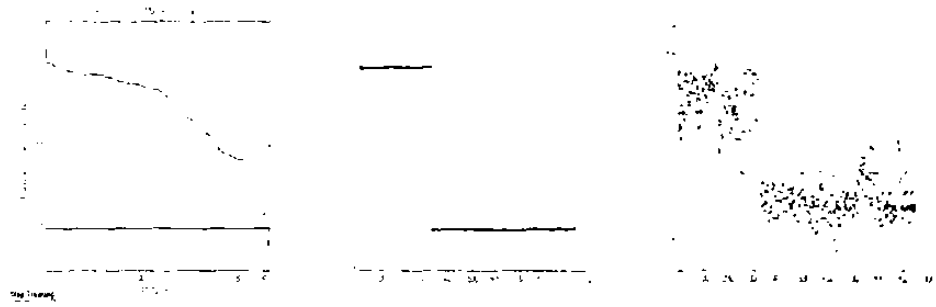

(a) Convergencia de la RNA (b) Prueba de clasificación (c) Prueba de generalización

Fig. 5.5 Entrenamiento y pruebas de un DF neuronal con patrones Delta y con una RNA de dos capas ocultas (16 muestras por ciclo).

Con la estructura de dos capas ocultas se alcanzó la convergencia en 93 iteraciones, en un tiempo de 31 minutos. La prueba de clasificación, con patrones utilizados en el entrenamiento, se muestra en la Fig. 5.5b. La Fig. 5.5c muestra los resultados de la prueba de generalización, que revela un desempeño de esta estructura superior al de las anteriores, pero aún deficiente.

Con estas pruebas fue validada la metodología propuesta para definir la RNA. Los ejemplos revelan que la metodología es aplicable para diferentes frecuencias de muestreo o representaciones de patrones. Un problema frecuente durante el entrenamiento de las RNA fue la insuficiente capacidad de cómputo.

5.4.2 Evaluación de prototipos de DF neuronales

La Tabla 5.1 resume las redes neuronales que fueron investigadas en esta etapa del trabajo. Después de realizar pruebas del tipo de las presentadas en la sección anterior, se establecieron las mejores estructuras de RNA para resolver el problema de DF. En total se realizaron alrededor de 600 pruebas, incluyendo las pruebas con patrones de entrenamiento, y las pruebas de generalización. Para cada uno de los 22 prototipos de RNA que se presentan en la Tabla 5.1 fue necesario definir la estructura de RNA y extraer los valores finales calculados para los pesos de la red. Otra actividad de

investigación consistió en determinar la mejor combinación ERD-RNA, antes de programar un prototipo de relevador neuronal y hacerle pruebas en tiempo real.

La construcción de la Tabla 5.1 representa la culminación de una etapa de diseño del algoritmo de DF. De las 22 variantes que se mencionan en la Tabla 5.1, todos los casos en que se utilizan ventanas de datos de medio ciclo (8 muestras de 16 m/c, ó 32 muestras de 64 m/c) no fueron objeto de un estudio más profundo, por el hecho de que existe la restricción de que el relevador debe operar entre un cuarto de ciclo y medio ciclo, lo que obliga a utilizar ventanas del orden de un cuarto de ciclo.

Un criterio que se adoptó en esta tesis para determinar el DF más apropiado, fue aplicar un ERD que produjera un estado transitorio que representara la mínima fuente de ruido: en ese sentido, el filtro Delta es el mejor. En la Tabla 5.1 fueron incluidas tres alternativas (las correspondientes a las filas 9, 10 y 11), que utilizan un filtrado tradicional, para fines de comparación. Por ser soluciones con ventana de datos de un ciclo, estas alternativas también fueron descartadas posteriormente. El ERD Modal es superior al de secuencias para esta aplicación **[87]**, porque produce el desacoplamiento de las señales transitorias con los modos naturales de propagación de la línea protegida y utiliza ventanas de longitud fraccionaria.

En las pruebas para determinar la estructura más adecuada para la clasificación de patrones en la función de DF, a cada una de las RNA se les entrenó con alrededor de 94.000 patrones. En la

TABLA 5.1 ESTRUCTURAS DE DF NEURONALES INVESTIGADAS.

Esquema	Número de neuronas			
	Capa de entrada	1ª Capa oculta	2ª Capa oculta	Capa de salida
1. Señales crudas, 5 muestras, 16 m/c	12	13	10	1
2. Señales crudas, 16 muestras, 64 m/c	16	18	9	1
3. ERD Δ, 5 muestras,16 m/c	8	12	6	1
4. ERD Δ 16 muestras, 64 m/c	16	14	7	1
5. ERD Modal, 5 muestras,16 m/c	18	10	3	1
6. ERD Daubechies 2, 4 muestras, 16 m/c	16	12	3	1
7. ERD Δ Modal, 5 muestras 16 m/c	18	14	7	1
8. ERD Δ- Daubechies 2, 4 muestras, 16 m/c	16	12	5	1
9. Fasores, 16 muestras, 16 m/c	16	8	3	1
10. Impedancias, 16 muestras, 16m/c	16	6	3	1
11. Secuencias 0+-, 16 muestras, 16 m/c	16	6	3	1
12. Señales crudas, 8 muestras,16 m/c	12	18	9	1
13. Señales crudas, 32 muestras, 64 m/c	16	18	9	1
14. Señales crudas- Modal, 32 muestras, 64 m/c	16	14	7	1
15. ERD Δ, 32 muestras, 64 m/c	22	17	7	1
16. ERD Daubechies 2, 8 muestras, 16 m/c	16	14	7	1
17. ERD Daubechies 2, 32 muestras, 64 m/c	16	18	9	1
18. ERD Δ- Daubechies 2, 8 muestras, 16 m/c	8	11	5	1
19. ERD Δ- Daubechies 2-Modal, 16 muestras, 64 m/c	16	14	7	1
20. ERD Δ- Daubechies 2-Modal, 32 muestras, 64 m/c	16	18	9	1
21. ERD Δ- Modal, 32 muestras, 64 m/c	16	11	8	1
22. ERD Daubechies 2-Modal, 32 muestras, 64 m/c	16	14	7	1

Tabla 5.2 se presentan los resultados de las pruebas de generalización realizadas a algunos de los DF indicados en la Tabla 5.1 y que exhibieron un buen desempeño. La Tabla 5.2 resume las pruebas a DF que tienen en común que utilizan patrones obtenidos de un procesamiento de 16 muestras por ciclo. La longitud de ventana de los DF de la Tabla 5.2 varía desde un cuarto hasta medio ciclo. El objetivo de estas pruebas fue

evaluar la capacidad de generalización de las RNA y reconocer el ERD que hace una mejor generalización cuando se maneja una frecuencia de muestreo relativamente baja. En la Tabla 5.2 se indican el número de casos de prueba aplicados a cada esquema, el número de casos en que la salida y es positiva ($y \geq 0$), y el número de casos en que y es no positiva ($y < 0$). Se utiliza ese criterio como filtro de salida para determinar la señal de salida del DF.

TABLA 5.2 DESEMPEÑO DE DF NEURONALES CON 16 MUESTRAS POR CICLO.

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y < 0$	% operaciones correctas	% fallos de operación
1. Señales crudas, 5 muestras, 16 m/c	3,128	1,939	1,157	62	37
2. ERD Δ, 5 muestras, 16 m/c	4,024	2,897	1,126	71	28
3. ERD Daubechies 2, 4 muestras, 16 m/c	3,514	2,284	1,229	65	35
4. ERD Δ- Modal, 5 muestras, 16 m/c	4,024	3,058	965	76	24
5. ERD Δ- Daubechies 2, 8 muestras, 16 m/c	3,619	2,460	1,158	68	32

De los resultados reportados en la Tabla 5.2 se pueden obtener varias conclusiones. Una primera es que en general, los ERD elevan la calidad de la clasificación con respecto al caso de señales crudas. De la comparación directa entre las Variantes 1 y 2 de esta tabla, se observa que el porcentaje de fallos de clasificación disminuye un 10%. Al combinar un ERD Delta y desacoplar las señales con los modos (Variante 4), se eleva aún más el nivel de desempeño (13% de reducción en fallos de clasificación). Esta combinación de ERD está orientada a eliminar información de prefalla y llevar a las RNA principalmente patrones de componentes transitorias de frecuencia no fundamental.

En esta Tabla 5.2 se puede ver que los DF con ERD basado en la onduleta Daubechies 2, apenas superan el desempeño del esquema de señales crudas. En las Variantes 3 y 5, la onduleta se convolucionó con 4 y 8 muestras respectivamente, y ambas longitudes de ventana obligan a utilizar patrones de componentes de baja frecuencia para detectar una falla. Se investigó el efecto de aumentar la longitud de ventana a medio ciclo, pero ello no mejoró la calidad en la clasificación, ni siquiera eliminando las componentes de prefalla con un ERD Delta.

Una conclusión general de la Tabla 5.2 es que ninguno de los DF allí reportados tiene un desempeño aceptable para aplicaciones prácticas. Los porcentajes de fallos de operación son todos superiores al 24%.

En la Tabla 5.3 se reportan los resultados de clasificar patrones para una frecuencia de muestreo de 64 muestras por ciclo. Se utiliza el mismo criterio explicado anteriormente como filtro de salida.

TABLA 5.3 DESEMPEÑO DE DF NEURONALES CON 64 MUESTRAS POR CICLO.

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y < 0$	% operaciones correctas	% fallos de operación
1. Señales crudas, 16 muestras, 64 m/c	3,190	1,786	1,403	56	44
2. ERD Δ, 16 muestras, 64 m/c	4,120	3,213	906	78	22
3. ERD Δ, 32 muestras, 64 m/c	4,120	3,419	701	83	17
4. ERD Δ-Daubechies 2, 16 muestras, 64 m/c	3,790	3,069	720	81	19
5. ERD Modal, 16 muestras, 64 m/c	3,914	3,092	821	79	21
6. ERD Δ- Modal, 16 muestras, 64 m/c	3,431	2,744	887	80	20

Lo primero a destacar de la Tabla 5.3 es que el desempeño del DF entrenado con señales crudas empeora con el aumento de la frecuencia de muestreo. A ese problema de baja calidad de la clasificación, se suma el problema de convergencia del algoritmo BP.

Se observa que en cinco de las variantes se manejan ventanas con longitud de un cuarto de ciclo (16 muestras). Los DF con ERD Delta tienen los mejores porcentajes de operaciones correctas. No obstante ello, apenas se supera el 80% de operaciones correctas, lo cual es inaceptable para aplicaciones prácticas.

Las variantes que ofrecieron el mejor nivel de desempeño en la clasificación de patrones de falla, medido de acuerdo con el porcentaje de errores de clasificación, son las basadas en el filtro Delta. Se pudiera pensar que aumentando la longitud de la ventana se mejora la clasificación, pero eso no se observó en las pruebas realizadas.

En los DF con ERD basado en onduletas, el aumento de la frecuencia de muestreo mejora el desempeño, pues se elevó en un 16% el porcentaje de clasificaciones correctas. Al aumentar la frecuencia de muestreo, el ERD basado en una onduleta Daubechies 2 reconoce mejor las componentes de alta frecuencia que se tienen en la ventana de datos.

El aumento de la frecuencia de muestreo de 16 a 64 muestras por ciclo no mejoró la calidad en la clasificación en todos los DF. Ha quedado fuera del alance de este trabajo de tesis probar DF con frecuencias de muestreo superiores. Sin embargo, el resultado anterior probó que los DF basados en onduletas tienen menos fallos de operación cuando reciben más muestras.

Para fines de comparación, en la Tabla 5.4 se reporta el desempeño de DF neuronales en que se utilizan filtros previos con ventana de un ciclo, que estiman información de frecuencia fundamental (rechazan las componentes transitorias provocadas por las fallas). En particular, las variantes de la Tabla 5.4 incluyen filtros que estiman fasores de magnitudes de fase, calculan impedancias como operadores fasoriales, o calculan fasores de componentes simétricas.

Se puede observar que estas alternativas superan algunos resultados de clasificación reportados en las dos tablas anteriores, pero continúan siendo inaceptables. La variante de clasificar señales de componentes simétricas tuvo menos fallos de

operación que las variantes basadas en clasificar los patrones de fasores o de las impedancias medidas por los elementos de distancia.

TABLA 5.4 DESEMPEÑO DE DF NEURONALES QUE RESPONDEN A PATRONES DE FRECUENCIA FUNDAMENTAL (16 MUESTRAS POR CICLO)

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y < 0$	% operaciones correctas	% fallos de operación
1. Fasores, 16 muestras, 16 m/c	3,150	2,236	913	71	29
2. Impedancias, 16 muestras, 16 m/c	3,150	2,331	819	74	26
3. Secuencias 0+- , 16 muestras, 16 m/c	3,150	2,488	661	79	21

Los resultados alcanzados en todas estas pruebas muestran un pobre desempeño de los elementos DF. En todos los casos las RNA fueron entrenadas con información de las tres fases. La conclusión fundamental de esta etapa de la investigación es que no se recomienda diseñar DF neuronales trifásicos. Por tanto, se recomienda para una investigación futura estudiar el comportamiento de elementos DF independientes para cada fase.

Se decidió entonces no utilizar un DF neuronal en el relevador desarrollado en este trabajo. El DF implementando en el prototipo de relevador neuronal es un conjunto de seis filtros delta, que detectan la presencia de un salto abrupto en alguna de las seis señales de entrada.

5.5 Clasificador neuronal de fallas (CF)

Los relevadores de distancia utilizan tres elementos independientes para protección contra fallas a tierra, y otros tres elementos para protección contra fallas entre fases (trifásicas y bifásicas) [85].

Los relevadores de protección de líneas de transmisión tienen por lo general algoritmos dedicados a clasificar los tipos de fallas. Estos algoritmos cumplen dos funciones [**1,5**]: a) iniciar el disparo de la fase fallada para fallas monofásicas a tierra. b) Permitir el disparo de los elementos de fase de la protección, y bloquear el disparo de los elementos de tierra, para fallas bifásicas a tierra. De acuerdo con lo anterior, los tipos de fallas a discriminar por un elemento DF son las monofásicas y las bifásicas a tierra. No se requiere discriminar las fallas trifásicas y bifásicas, pues para ambos tipos de fallas el disparo del interruptor es tripolar.

Para la clasificación de fallas, en este trabajo se utilizan 10 RNA, entrenada cada una de ellas para identificar uno de los 10 tipos de fallas: 1) Falla de fase A a tierra (A-T), 2) Falla de fase B a tierra (B-T), 3) Falla de fase C a tierra (C-T), 4) Falla entre fases A y B (A-B), 5) Falla entre fases A y C (A-C), 6) Falla entre fases B y C (B-C), 7) Falla entre fases B-C y tierra (B-C-T), 8) Falla entre fases B-C y tierra (B-C-T), 9) Falla entre fases B-C y tierra (B-C-T) y, 10) falla trifásica (A-B-C). En la Fig. 4.22 se hizo referencia a la formación de dicotomías para abordar estos 10 problemas de clasificación de patrones.

La Fig. 5.6 representa la estructura interna del clasificador neuronal de fallas. Se muestran las RNA utilizadas para clasificar los 10 tipos de fallas, y los elementos adyacentes al bloque CF. Para clasificar cada tipo de falla se requiere una estructura de red y un banco de patrones diferente.

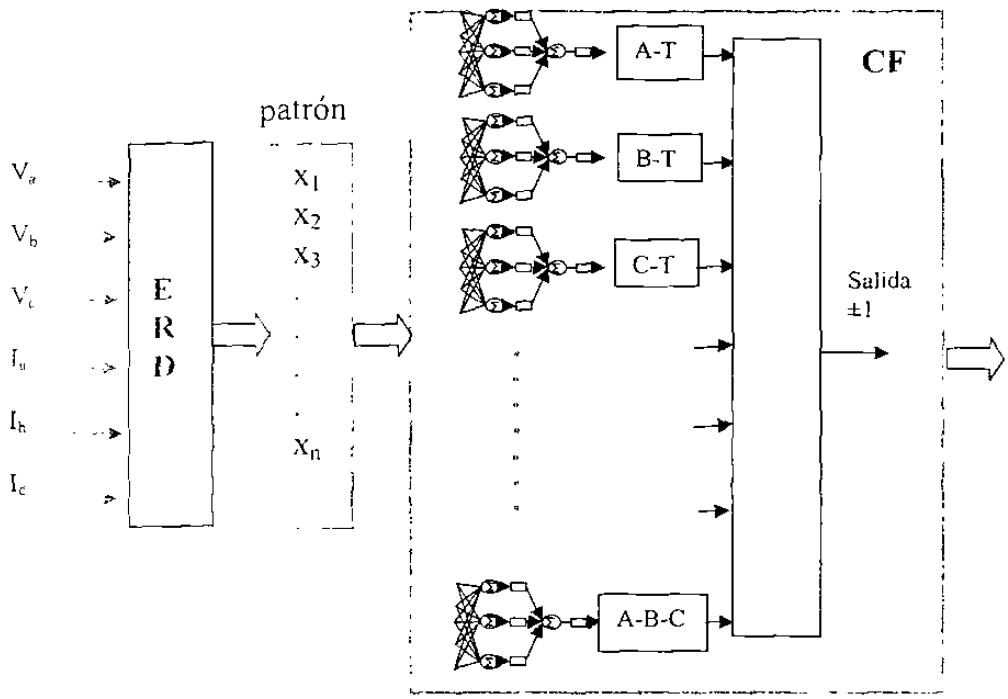

Fig. 5.6 Estructura interna del elemento clasificador neuronal de fallas.

Cabe observar que, en operación de tiempo real, las 10 RNA reciben a su entrada el mismo patrón; por ello, para cada falla, el bloque DF emite una señal de falla (+1), correspondiente al tipo de falla que ocurrió, y nueve señales de no falla (-1). En este capítulo se estudia el desempeño individual de las RNA del bloque CF de la Fig. 5.6. El interés se centra en definir la RNA y valorar los porcentajes de error de clasificación de las distintas salidas de tipo binario.

5.5.1 Diseño de prototipos de CF neuronales

En esta sección se aplica también la metodología descrita en la Sección 5.3 para definir la estructura de RNA más adecuada para cada uno de los diez CF neuronales.

El diseño de cada RNA implica una gran carga computacional, tanto para generar los bancos de patrones, como para llevar a cabo el entrenamiento. Después de muchas pruebas, en el diseño de las RNA para la tarea de CF se decidió no utilizar patrones correspondientes a las ventanas de la etapa de transición entre los estados de prefalla y falla. Es decir, en las RNA de los CF se utilizan solo patrones formados con ventanas

llenas con información de falla. En la práctica, esto implica contar en el relevador con una lógica que permita esperar un tiempo igual a la longitud de ventana antes de emitir un criterio de selección de fases falladas. Con una ventana de un cuarto de ciclo esto no es un problema.

Los cambios bruscos en los valores instantáneos de las corrientes son un indicativo del tipo de falla. La propagación de esas señales a través de los distintos conductores se puede visualizar más fácilmente si se desacoplan las señales. Este es otro recurso adoptado en este trabajo para acotar el estudio de esquemas neuronales para CF, pero solo se utiliza el desacoplamiento de señales con los modos naturales de propagación

Para las pruebas que se presentan a continuación, cada banco de patrones de los CF fue dividido en dos grupos:

1. Un grupo representa el tipo de falla que ocurrió. Las fallas de ese tipo se aplican dentro y fuera de la zona protegida. Esa condición se asocia con la salida +1 de la RNA. Está formado por unos 4,200 vectores, generados para 43 fallas del mismo tipo. Los diferentes casos resultan de plantear fallas en 5 puntos de la línea, con 12 valores de resistencia de falla y con 16 instantes de ocurrencia de cada falla.
2. El otro grupo representa patrones de los otros nueve tipos de falla, también dentro y fuera de la zona protegida, así como otros estados del sistema de potencia. Estos patrones se asocian con la salida −1. Está formado por 7,100 vectores, generados para 720 fallas distintas a las del grupo anterior. También se incluyen 12 operaciones de cierre de interruptores y 64 operaciones de apertura (16 en cada nodo del sistema de la Fig. 3.10), dos oscilaciones de potencia estables y dos inestables, y cinco estados normales de carga.

Se tienen entonces diez bancos de patrones y cada uno contiene aproximadamente 11,300 patrones. Con estos bancos se definen las estructuras y parámetros de las RNA.

5.5.2 Evaluación de prototipos de CF neuronales

En esta sección se resumen los resultados de la evaluación de prototipos de CF neuronales. Para esta aplicación solo se requirieron estructuras de RNA de una capa oculta. La capa de entrada fue en todos los casos de 7 neuronas. El muestreo con el que se

generaron los patrones de los bancos es de 16 muestras/ciclo. Para definir el número de neuronas de la capa oculta se comenzó con 15 neuronas y el algoritmo de regularización permitió definir N=7 como un número de neuronas adecuado. A continuación se probaron RNA con N=5,6,7 y 8. La Tabla 5.5 resume las estructuras que ofrecieron el mejor desempeño en el problema de clasificación de las fallas monofásica a tierra.

TABLA 5.5 ESTRUCTURAS DE RNA MÁS ADECUADAS PARA CF DEDICADOS A FALLAS MONOFÁSICAS A TIERRA.

	Número de neuronas		
	Capa de entrada	Capa oculta	Capa de salida
1. Señales crudas	7	5	1
2. ERD Δ	7	4	1
3 ERD Daubechies 2	7	7	1
4. ERD Modal	7	3	1

El menor tiempo de entrenamiento correspondió al CF que utiliza el ERD basado en los modos de preparación. Esto era de esperarse, debido a que se concluyó en el Capítulo 3 que así se detecta la excitación del modo de tierra. En todas estas estructuras se alcanzó la convergencia en menos de 100 iteraciones.

En las Tablas 5.6 y 5.7 se resumen los resultados de las pruebas realizadas a las RNA que tienen las estructuras mostradas en la Tabla 5.5. La Tabla 5.6 resume el desempeño del CF A-T en sus cuatro posibles variantes para fallas de A a tierra. La Tabla 5.7 muestra el desempeño de ese mismo CF para los otros nueve tipos de fallas. Es importante aclarar que entre los patrones de prueba había alrededor de un 15% de casos que no son fallas (aperturas/cierres de interruptores y oscilaciones de potencia). Es decir, se está intrínsicamente probando el CF también como un DF. En la operación real en el relevador, el CF solo debe clasificar fallas cuando el DF lo active. Por tanto, el CF por lo general no tendrá que discriminar entre fallas y otras condiciones. En resumen, las pruebas que se reportan en las Tablas 5.6 y 5.7 son muy exigentes. El desempeño real del CF debe ser aún mejor. En el Capítulo 6 se comprobará esto.

TABLA 5.6 DESEMPEÑO DEL CF DE A-T PARA FALLAS A-T.

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y<0$	% clasificaciones correctas	% fallos de clasificación
1. Señales crudas	1,024	765	157	74.7	15.3
2. ERD Δ	1,312	1,132	178	86.3	13.7
3. ERD TWD	967	752	214	78.0	22.1
4. ERD Modal	1,044	1,014	29	97.2	2.8

TABLA 5.7 DESEMPEÑO DEL CF DE A-T PARA LOS OTROS NUEVE TIPOS DE FALLAS

	Resultados				
	Casos de prueba	# salidas con $y<0$	# salidas con $y/0$	% clasificaciones correctas	% fallos de clasificación
1. Señales crudas	3,112	2,259	852	72.6	27.4
2. ERD Δ	2,960	2,492	467	84.2	15.8
3. ERD Daubechies 2	2,728	2,212	515	81.1	18.9
4. ERD Modal	3,219	3,164	34	98.3	1.07

De estas pruebas se puede concluir que los mejores resultados corresponden al ERD modal, es decir, que manejar señales desacopladas facilita la tarea de clasificación de patrones de fallas a tierra. En las pruebas de generalización a esquemas en que no se pre-procesa la información de entrada a las RNA (no mostrados en la tesis por razones de espacio), se tiene un elevado porcentaje de fallos.

Todos los CF evaluados utilizan RNA de una sola capa oculta. Los resultados obtenidos son buenos para el ERD Modal, que clasifica correctamente más del 97% de las fallas. Es de esperar que RNA de dos o más capas ocultas den aún mejores resultados, por lo que se recomienda estudiar DF con RNA de dos o más capas en investigaciones futuras.

La frecuencia de muestreo fue de 16 muestras por ciclo para todos los CF estudiados. Los resultados de las pruebas indican que no se requiere una frecuencia de muestreo más elevada para esta tarea.

TABLA 5.8 DESEMPEÑO DE ESQUEMAS CF CON ERD MODAL.

	RESULTADOS				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y < 0$	% clasificaciones correctas	% fallos de clasificación
1. FALLAS A-T	1,025	997	28	97.2	2.8
2. FALLAS B-T	1,025	1,004	20	97.6	2.4
3. FALLAS C-T	1,025	998	27	97.4	2.6
4. FALLAS A-B	1,025	970	55	94.6	5.4
5. FALLAS A-C	1,025	961	64	93.8	6.2
6. FALLAS B-C	1,025	981	44	95.7	4.3
7. FALLAS A-B-T	1,025	1,000	25	97.6	2.4
8. FALLAS A-C-T	1,025	1,004	19	98.1	1.9
9. FALLAS B-C-T	1,025	998	27	97.4	2.6
10. FALLAS A-B-C	1,025	1,016	9	99.1	0.9

La Tabla 5.8 resume los resultados de evaluar los 10 CF desarrollados para cada uno de los distintos tipos de fallas. Estos esquemas utilizan el ERD Modal. Todas las pruebas que se reportan en esta tabla se le hicieron a una RNA con 8, 3 y 1 neuronas respectivamente. Aunque los 10 CF tienen la misma estructura, los pesos de las neuronas resultaron ser muy diferentes.

Con estas pruebas se puede observar que en general, el comportamiento de los CF para todas las fallas que involucran tierra es similar (entre 2 y 3 % de fallos de clasificación). Esto indica que la información aportada por el modo de tierra es dominante para fallas a tierra de todos los tipos. Los mejores resultados se obtienen para fallas trifásicas (0.9% de fallas). Para fallas bifásicas los errores son del orden del 4-6%. Como se señaló al inicio de esta sección, la clasificación de fallas bifásicas no es

relevante para aplicaciones prácticas. El uso de RNA con dos o más capas ocultas, debe mejorar este comportamiento, lo que se recomienda estudiar en investigaciones futuras.

Como se comentó anteriormente, las pruebas realizadas al CF son muy exigentes. Aún así, los resultados obtenidos son superiores a los reportados en trabajos anteriores sobre clasificadores neuronales [**32,57,70,89,105**]. Es de esperar que esos resultados mejoren aún más en la operación real, en que el CF solo recibe información de fallas, al ser activado por el DF en el relevador. No existen datos de desempeño de clasificadores de fallas basados en algoritmos tradicionales.

5.6 Estimador neuronal de zona de falla (EZF)

En protecciones tradicionales de líneas de transmisión se requiere un canal de comunicaciones para garantizar el disparo instantáneo para todas las fallas en el 100% de la línea protegida.

En algunos países se trata de acelerar la operación de la protección de distancia sin canal de comunicaciones, haciendo un primer disparo instantáneo utilizando el elemento de segunda zona, que sobrealcanza el extremo remoto de la línea protegida. Si la falla es en la línea protegida, se logra una operación correcta instantánea. Sin embargo, para fallas al inicio de la línea adyacente y dentro de la segunda zona, el disparo es incorrecto, y debe ser corregido con un recierre automático de la línea adyacente. Es decir, la cobertura de disparo instantáneo para fallas en el 100% de la línea protegida sin canal de comunicaciones se logra a expensas de una pérdida de seguridad del relevador, que opera incorrectamente para algunas fallas en la línea adyacente y provoca pérdidas transitorias de servicio en esa línea.

Un objetivo de esta tesis es lograr que el relevador neuronal detecte fallas en el 100% de la longitud de la línea protegida e inicie el disparo instantáneo, sin necesidad de canal de comunicaciones. Esa es la función del elemento denominado estimador de zona de falla (EZF) del relevador neuronal.

La tarea del EZF consiste en detectar las fallas en el 100% de la longitud de la línea protegida y emitir una señal de disparo instantáneo, y en no operar para fallas en

líneas adyacentes a la protegida, o para otras condiciones de operación del sistema de potencia.

En la Fig. 5.7 se muestra el sistema de potencia utilizado comosistema de prueba en esta tesis. El relevador neuronal está localizado en la barra B y protege la línea BC. De esta forma, el relevador debe operar instantáneamente para fallas en la línea BC (Zona 1) y no operar para fallas en las líneas CD (Zona 2) y AB (Zona 3).

5.6.1 Estimador neuronal de zona de falla con una RNA

En esta alternativa se entrena una única RNA para realizar la discriminación entre fallas internas y externas. Este EZF fue estudiado en dos etapas de desarrollo. En la primera etapa se utilizó un SEP balanceado y se aplicaron solo fallas trifásicas [75]. En la segunda etapa se estudió el problema completo, con un SEP asimétrico y todo tipo de fallas. En esta etapa se aplicó el procedimiento descrito en el diagrama de la Fig. 4.8 para obtener los patrones. En este problema de reconocimiento de patrones del EZF, se requiere un banco de patrones con las características indicadas en el Capítulo 4.

Para las pruebas que se realizaron, el banco de patrones de los EZF fue dividido en dos grupos:

1. Un grupo representa la clase de una falla en la zona protegida, que implica un disparo del relevador. Este grupo se asocia con la salida +1 de la RNA. Está formado por unos 9,000 vectores (cada vector corresponde a una ventana de datos), generados para 2,304 fallas trifásicas en la línea protegida (línea BC en la Fig. 3.10). Los diferentes casos resultan de plantear fallas en 12 puntos de la línea, con 12 valores de resistencia de falla y con 16 instantes de ocurrencia de cada falla.
2. El otro grupo es la clase de no falla en la zona protegida, que implica la no operación del relevador, y se asocia con la salida −1 de la RNA. Está formado por unos 15,000 vectores, generados para 1,020 fallas trifásicas en las líneas adyacentes, 64 operaciones de cierre de interruptores y 64 operaciones de apertura (16 en cada nodo del sistema de la Fig. 5.7), dos oscilaciones de potencia estables y dos inestables, y cinco estados normales de carga.

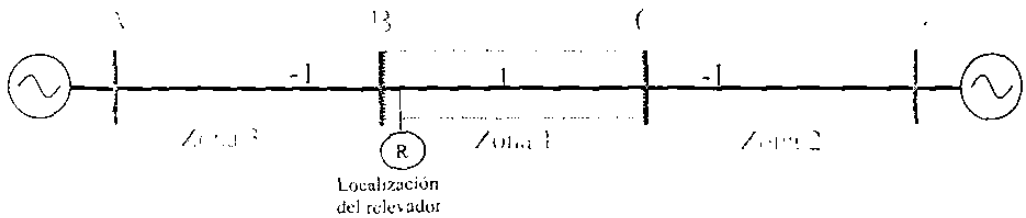

Fig. 5.7 Sistema de potencia de prueba en que se muestran las zonas de protección.

De aproximadamente 24,000 patrones generados, se utilizó la mitad (vectores pares) para el entrenamiento de las RNA y la otra mitad (vectores impares) para las pruebas. Se concentró la atención en definir las estructuras y parámetros de las RNA para reconocer los distintos patrones.

En forma similar que con los DF, se aplicó la metodología descrita en la Sección 5.3 para definir la estructura de RNA más adecuada para cada EZF. Conociendo el problema resultante de incluir en el entrenamiento los patrones generados durante el estado de transición de prefalla a falla, para el EZF se excluyen esos patrones y solo se utilizan los patrones formados con ventanas totalmente llenas con información de falla. Tal como se comentó en el caso del DF, con una ventana de un cuarto de ciclo el retardo en la operación del relevador no es significativo.

A continuación se resumen los resultados del entrenamiento y pruebas de prototipos de EZF neuronales. Para las estructuras de una sola capa oculta, se comenzó con 15 neuronas y el algoritmo de regularización permitió definir N=9 como un número de neuronas adecuado. Posteriormente se probaron RNA con N=5,6,7,8, 9 y 10, entrenadas con Levemberg-Marquard. Las pruebas de generalización no dieron buenos resultados; por ello, se pasó a estudiar estructuras de dos capas ocultas. La Tabla 5.9 resume las cuatro estructuras de dos capas ocultas que ofrecieron el mejor desempeño. Se

incluye también en la Tabla 5.9 el prototipo que opera con señales crudas, para fines de comparación.

TABLA 5.9 ESTRUCTURAS DE RNA MÁS ADECUADAS PARA LOS DISTINTOS EZF.

	Número de neuronas			
Esquema	Capa de entrada	1ª Capa oculta	2ª Capa oculta	Capa de salida
1. Señales crudas	10	8	3	1
2. ERD Δ	10	7	3	1
3. ERD Daubechies 2	8	5	5	1
4. ERD Δ-Daubeches 2	8	5	5	1
5. ERD Modal	8	5	3	1

Al comparar la Tabla 5.9 con la Tabla 5.1, se puede observar que, en general, las estructuras de RNA para EZF tienen menor número de neuronas en las capas ocultas que las RNA para DF. El menor número de neuronas y la no inclusión de patrones de la transición del estado de prefalla a falla hicieron más fácil el entrenamiento, y demandaron un menor número de iteraciones para llegar a la convergencia con un 0.0001 de error. De las estructuras que se presentan en la Tabla 5.9, las dos que tienen ERD convergieron en alrededor de 15 minutos. El EZF entrenado con señales crudas necesitó 211 iteraciones y 44 minutos para llegar a la convergencia.

En las Tablas 5.10 y 5.11 se resumen los resultados de las pruebas realizadas a las RNA que tienen las estructuras mostradas en la Tabla 5.9, que resultaron ser las de mejor desempeño. Se utiliza como filtro de salida, para determinar si se genera o no la señal de disparo, la comparación con cero de la salida de la RNA ($y > 0$ es una condición de disparo y, $y < 0$ es una condición de no disparo). De esta forma se determinan los porcentajes de operaciones correctas y fallos de operación para fallas en la zona protegida, y los porcentajes de no operaciones correctas y de operaciones incorrectas para condiciones de no falla en la zona protegida. Estas pruebas son todas considerando una frecuencia de muestreo de 16 muestras/ciclo y la misma longitud de ventana de un cuarto de ciclo para todos los EZF.

2. El EZF que utiliza señales crudas es el de peor desempeño. Este esquema fue también el que requirió mayor número de iteraciones en el proceso de aprendizaje.
3. La adición de un extractor de rasgos distintivos (ERD) reduce el tiempo de entrenamiento y mejora el desempeño de las RNA. Esto indica que el ERD aligera la carga computacional del aprendizaje de las neuronas, al generar patrones más fácilmente reconocibles por las RNA.
4. Los mejores resultados corresponden al ERD basado en el filtro delta. El ERD basado en onduletas no da resultados satisfactorios en esta prueba, y empeora el desempeño del filtro delta al utilizarse en forma conjunta con éste.
5. La alternativa de desacoplar las señales crudas con los modos de propagación (ERD Modal) reduce el número de iteraciones requerido para llegar al error de tolerancia, pero no supera los resultados del EZF con filtro Delta.

Es importante resaltar que se utilizó una frecuencia de muestreo de 960 Hz (16 muestras por ciclo) y un filtro antialiasing con una frecuencia de corte de 360 Hz. Esto limita significativamente la información de alta frecuencia que llega a la entrada del ERD basado en onduletas. Es necesario continuar en el futuro esta evaluación con frecuencias de muestreo más elevadas. Se espera un mejor desempeño del ERD basado en onduletas para este caso.

Con estas pruebas se confirmó que excluir del entrenamiento los patrones de la transición del llenado de ventana eleva en forma considerable la calidad de la clasificación y de generalización. En el relevador neuronal, por tanto, se requiere una lógica para inhibir el disparo durante un tiempo igual al que dura la transición, que es la longitud de la ventana de datos. Como se ha señalado anteriormente, con una ventana de un cuarto de ciclo el retardo en la operación no es significativo.

5.6.2 Estimador neuronal de zona de falla con dos RNA

En las pruebas realizadas al EZF que tiene solo una RNA se obtuvieron resultados aceptables, pero es conveniente disponer de otra alternativa de solución antes de pasar a las pruebas de operación del relevador neuronal que se describen en el Capítulo 6. Esa

otra alternativa consiste en separar en dos funciones la tarea de estimación de la zona de falla.

En la Fig. 5.8 se muestra la forma en que se segrega al EZF en dos funciones, a ser desempeñadas por dos RNA. Una RNA tiene la tarea de estimar la dirección de la falla con respecto a la ubicación del relevador. Esta solución, reportada en [30] para el caso monofásico, ha sido extendida en esta tesis para el problema trifásico. Este elemento se denomina estimador direccional (ED). La formulación básica se obtiene agrupando en una clase a todo tipo de fallas presentes en las Zonas 1 y 2, asignándoles una salida +1. El otro grupo incluye sólo fallas detrás del relevador, en la Zona 3, y se les asigna una salida de -1.

El segundo problema a solucionar consiste en estimar las fallas que ocurren en la línea adyacente a la protegida hacia delante (línea CD o Zona 2), diferenciándolas de las fallas en la línea protegida (línea BC o Zona 1), y en la línea adyacente hacia atrás (línea AB o Zona 3). Este elemento se denomina estimador de falla en la línea adyacente (EFLA).

En la formulación básica, a las fallas en la Zona 2 se les asigna una salida +1 de la RNA, y a las fallas en las Zonas 1 y 3 se les asigna una salida -1.

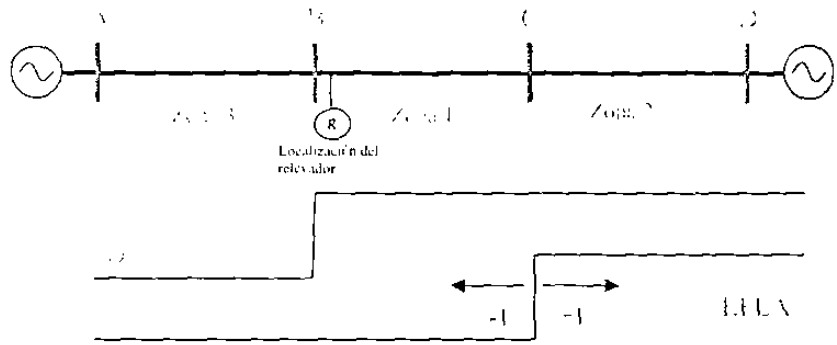

Fig. 5.8 Separación del EZF en un estimador direccional (ED) y un estimador de fallas en la línea adyacente (EFLA).

La Fig. 5.9 muestra la lógica que se implementa para formar la señal de disparo a partir de la salida del ED y el EFLA. El elemento estimador direccional (ED) permite implementar una protección piloto por comparación direccional si se dispone de un canal

de comunicaciones. El estimador de fallas en líneas adyacentes (EFLA) complementa la solución de discriminación de zona para una protección de primera zona sin canal de comunicaciones, orientada a cubrir el 100% de la línea protegida en forma instantánea.

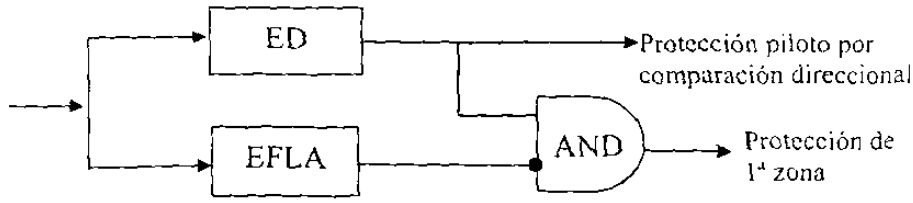

Fig. 5.9 Lógica de disparo del EZF formado por un ED y un EFLA.

Se decidió diseñar las RNA para esta alternativa de solución solamente en la variante que utiliza un filtro Delta como ERD, que fue la mejor solución para el ERD con una RNA, descrito en la sección anterior. Se decidió también aumentar la frecuencia de muestreo a 64 muestras por ciclo.

Para determinar el número de capas ocultas y el número de neuronas de cada capa de las RNA destinadas a las funciones de ED y EFLA, se siguió la misma metodología que en las secciones anteriores de este Capítulo. La Tabla 5.12 resume la estructura de RNA que resultó adecuada para ambas RNA (ED y EFLA).

TABLA 5.12 ESTRUCTURA DE RNA MÁS ADECUADA PARA ED Y EFLA.

	Número de neuronas			
Esquema	Capa de entrada	1ª capa oculta	2ª capa oculta	Capa de salida
ERD Δ	16	9	4	1

En las Tablas 5.13 y 5.14 se resumen los resultados de las pruebas de desempeño del ED compuesto por una RNA con la estructura dada en la Tabla 5.12.

TABLA 5.13 DESEMPEÑO DEL ED PARA FALLAS HACIA ADELANTE.

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y<0$	% operaciones correctas	% fallos de operación
ERD Δ	2325	2255	69	97.63	2.37

TABLA 5.14 DESEMPEÑO DEL ED PARA FALLAS HACIA ATRÁS.

	Resultados				
	Casos de prueba	# salidas con $y<0$	# salidas con $y/0$	% no operaciones correctas	% de operaciones incorrectas
ERD Δ	6240	5928	312	95.1	4.9

De las Tablas 5.13 y 5.14 puede concluirse que los resultados del ED son comparables con los del EZF compuesto por una sola RNA. Es necesario estudiar por separado el comportamiento del EFLA y posteriormente evaluar el comportamiento de la combinación de ambos, operando según la lógica de disparo de la Fig. 5.9.

En las Tablas 5.15 y 5.16 se resumen los resultados de las pruebas de desempeño del EFLA compuesto por una RNA con la estructura dada en la Tabla 5.12.

TABLA 5.15 DESEMPEÑO DEL EFLA PARA FALLAS EN LA LÍNEA CD (ZONA 2).

	Resultados				
	Casos de prueba	# salidas con $y \geq 0$	# salidas con $y<0$	% operaciones correctas	% fallos de operación
ERD Δ	5000	4915	85	98.3	1.7

TABLA 5.16 DESEMPEÑO DEL EFLA PARA FALLAS EN LAS LÍNEAS BC (ZONA 1) Y AB (ZONA2).

	Resultados				
	Casos de prueba	# salidas con $y<0$	= salidas con $y/0$	% no operaciones correctas	% operaciones incorrectas
ERD Δ	5000	4630	370	92.6	7.4

En las Tablas 5.15 y 5.16 pueden también observarse comportamientos del EFLA que son comparables con los obtenidos para el ED, y para el EZF compuesto por una sola RNA. Es necesario evaluar el comportamiento de la combinación del ED y el EFLA, operando según la lógica de disparo de la Fig. 5.9, y compararlo con el desempeño del EZF de una sola RNA. Esa evaluación y comparación se hacen en el Capítulo 6.

5.7 Conclusiones del capítulo

En este capítulo se estableció la estructura general del tipo de RNA a utilizar en el relevador neuronal. Se seleccionó una red tipo perceptrón multicapa, con todas sus neuronas interconectadas, y entrenados con el algoritmo de retropropagación del error (BP). Las neuronas de la capa de salida tienen una función de activación Signo, y las restantes neuronas tienen funciones de activación Sigmoide o Tangente Hiperbólica.

Se estableció una metodología de diseño de las estructuras de RNA a utilizar en el relevador. Se comienza con una RNA de una capa oculta y un número alto de neuronas, que se entrena por BP con regularización. Se eliminan las neuronas con pesos muy bajos, y se define el número N de neuronas útiles. Se entrena esa red por BP (Levemberg-Marquard) y se hacen pruebas de desempeño a esa RNA y a otros con números de neuronas cercanos a N. Si el resultado es bueno, se selecciona esa RNA; si no, se repite el proceso con RNA de dos o más capas ocultas, hasta encontrar la adecuada.

Se investigó el posible desarrollo de un detector neuronal de fallas trifásico. Se estudiaron 22 posibles estructuras de RNA, con combinaciones de las siguientes variables: a) Frecuencias de muestreo de 16 y 64 muestras por ciclo. b) Ventanas de

datos de 1/4, 5/16, 1/2 y 1 ciclo. c) Señales de entrada sin filtrar (crudas) o pre-procesadas en un extractor de rasgos distintivos (ERD). d) Tipos de ERD: Filtro Delta, ERD Modal, Onduleta Daubechies 2, combinaciones de estas, y filtros de extracción de fasores.

De las pruebas realizadas se concluyó que ninguna de estas alternativas es apropiada para un detector de fallas trifásico. Se utilizará en el relevador neuronal un detector de fallas tradicional basado en el filtro Delta. Se recomienda profundizar en el futuro el estudio de los detectores de fallas monofásicos, de los que se ha reportado un buen desempeño en trabajos anteriores.

Se estudiaron varias estructuras de RNA para realizar la función de clasificación de fallas. Se encontró que una red con 7 neuronas de entrada, 3 en la capa oculta y una de salida cumple bien esta función, cuando es precedida por un extractor de rasgos distintivos de tipo modal. Esta RNA tiene buen desempeño incluso para 16 muestras por ciclo.

Se investigaron dos alternativas de estimadores de zona de falla neuronales. En la primera alternativa, una única red de neuronas fue entrenada para discriminar entre fallas en el 100% de la línea protegida, y fallas en otras líneas. Se añadieron condiciones de no falla a los patrones de entrenamiento. Los mejores resultados se obtuvieron con una RNA con 10 neuronas de entrada, 7 en la primera capa oculta, 3 en la segunda y una de salida, precedida por un extractor de rasgos distintivos tipo Delta.

La segunda alternativa consiste en separar la estimación de zona de falla en dos funciones, un estimador direccional (ED), y un estimador de fallas en líneas adyacentes (EFLA). Para ambas funciones resultó adecuada una RNA con 16 neuronas de entrada, 9 en la primera capa oculta, 4 en la segunda y una de salida, precedida por un extractor de rasgos distintivos tipo Delta.

Es necesario hacer pruebas de operación del relevador neuronal como un todo, incluyendo su lógica de disparo, para seleccionar una de las dos alternativas de EZF. Esas pruebas de operación se describen en el Capítulo 6.

CAPÍTULO VI

EVALUACIÓN DE UN PROTOTIPO DE RELEVADOR NEURONAL DE PROTECCIÓN DE LÍNEAS DE TRANSMISIÓN

6.1 Introducción

En este capítulo se reportan las pruebas realizadas a un prototipo de relevador neuronal. Se analiza la operación del relevador a nivel de simulación digital, una vez que se describe la lógica de disparo que se programó en el prototipo. Con las pruebas se determinan los índices de operación ante fallas internas, fallas externas, y otras condiciones anormales de operación.

6.2 Diseño del prototipo de relevador

En el Capítulo 2 se presentaron dos estructuras básicas de un relevador neuronal: una sin extractor de rasgos distintivos (ERD) (Fig. 2.8), y otra con ERD (Fig. 2.9). Posteriormente, en el Capítulo 5 se estableció la necesidad de utilizar un ERD en los CF y EZF neuronales. En ese capítulo también se definieron las estructuras de RNA a utilizar en los CF y EZF neuronales.

A continuación se describe la estructura general del prototipo de elemento neuronal instantáneo desarrollado en esta tesis, que utiliza un ERD, y que sigue la concepción general del esquema de la Fig. 2.9.

6.2.1 Estructura del prototipo de elemento neuronal instantáneo

La Fig. 6.1 muestra el diagrama lógico del prototipo de relevador de protección de líneas de transmisión. El prototipo fue programado en MATLAB. Se trata de un elemento

instantáneo, destinado a un esquema de protección piloto por comparación direccional, o a la primera zona de un relevador de distancia. Como elemento de primera zona, tiene la ventaja de lograr la protección instantánea en el 100% de la línea protegida sin canal de comunicaciones.

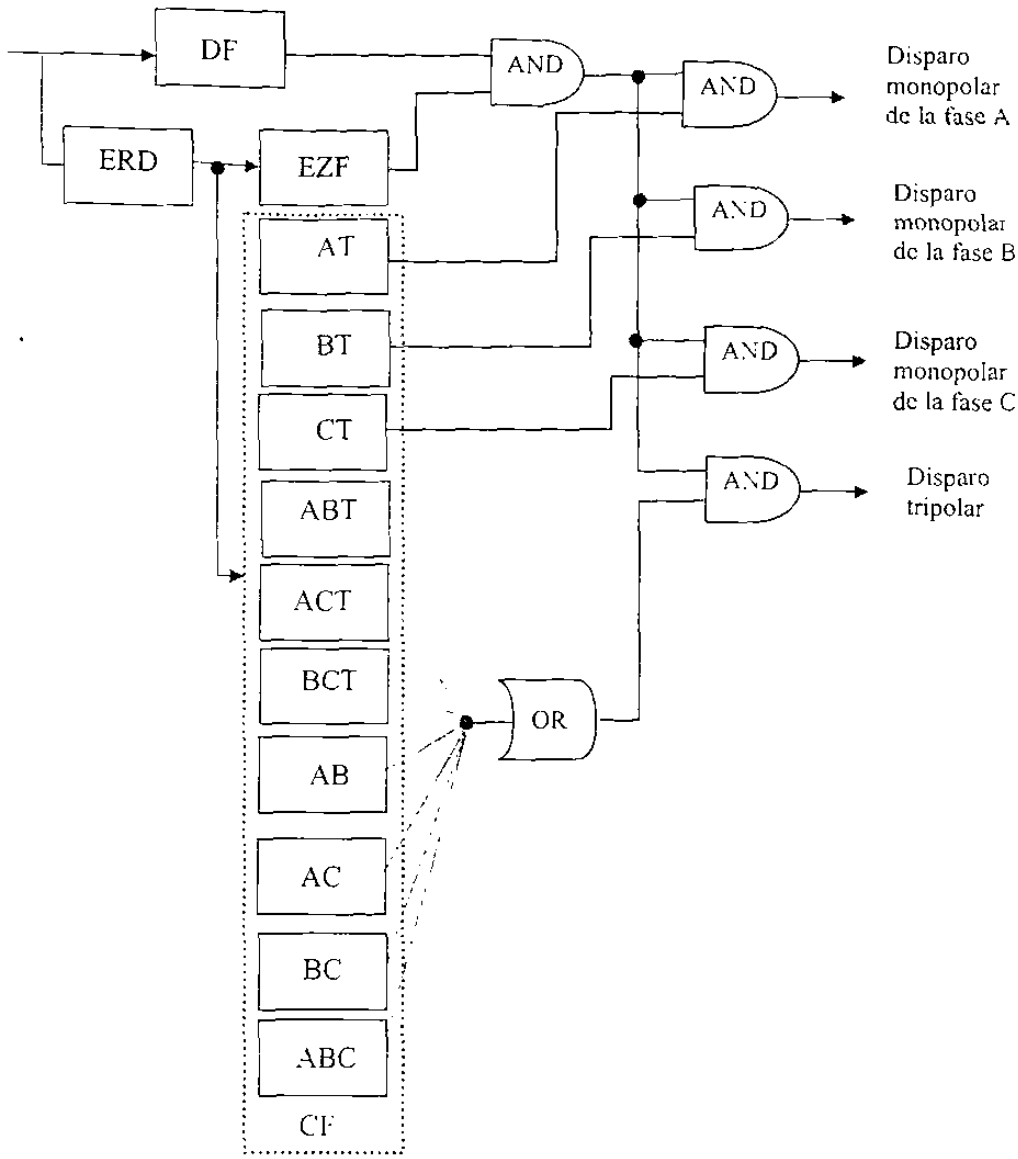

Fig. 6.1 Lógica de operación del relevador neuronal.

En el Capítulo 5 se estableció que el detector de fallas (DF) está compuesto por elementos monofásicos que responden a las magnitudes incrementales. El DF se diseña para operar siempre que se rebase un valor umbral por cualquiera de las seis señales incrementales de entrada al relevador; las señales de salida del DF se utilizan para activar de manera instantánea los otros dos bloques básicos del esquema neuronal, para las tareas de CF y EZF.

El EZF es un elemento clave del esquema neuronal, porque es el que determina la presencia de fallas dentro de la línea de transmisión protegida. En el Capítulo 5 se propusieron dos alternativas de EZF (con una y con dos RNA). En este capítulo se analizan comparativamente ambas alternativas en base a los resultados de las pruebas del prototipo.

El bloque CF se forma de diez RNA, por las que se propagan simultáneamente los patrones que se reciben en cada instante de muestreo del relevador. Inicialmente, las salidas de estas RNA están reposicionadas en un valor cero; sólo se activan si reciben la señal de arranque del elemento DF. De las diez señales de tipo binario que salen instantáneamente del CF, una de ellas, la correspondiente al tipo de falla que ocurrió, debe ser +1; también deben tenerse nueve señales de no disparo (-1) en las salidas de las otras nueve RNA.

Puede observarse en la Fig. 6.1 que las salidas de las RNA del CF y el EZF se procesan en un esquema lógico para elaborar la señal de disparo. En esquemas de protección con disparo monopolar de interruptores se necesitan las cuatro salidas de disparo mostradas en la Fig. 6.1. La idea básica de la lógica consiste en utilizar las salidas de fallas monofásicas (AT, BT, CT) del CF para emitir las señales de disparo monopolar de la fase correspondiente. Las siete salidas del CF correspondientes a fallas de dos o más fases, se combinan en una compuerta OR e inician el disparo tripolar.

Los elementos CF y EZF del prototipo de relevador cuentan con una lógica que inhibe la operación de las RNA desde el inicio de la falla, hasta que la ventana de datos se llena completamente con información del estado de falla. Cada red neuronal del prototipo tiene a su salida un filtro que convierte a +1 ó -1 la señal de salida de la red. Los elementos CF y EZF también tienen a su salida un contador de operaciones ajustado a tres

disparos. Por tanto, la salida final de disparo del CF y el EZF se genera cuando se tienen tres señales de disparo consecutivos. En este capítulo se fundamenta la necesidad de los contadores de operaciones.

6.2.2 Características del prototipo de relevador neuronal

El prototipo de relevador neuronal probado en este capítulo tiene las características siguientes:

1. La frecuencia de muestreo es de 64 muestras por ciclo de frecuencia fundamental.
2. En el EZF se utiliza un ERD Delta para el pre-procesamiento de las señales a presentar a las RNA.
3. Los patrones de señales de entrada se forman de agrupar seis ventanas de datos, una por cada variable.
4. La longitud de la ventana de datos es de un cuarto de ciclo.
5. Se inhibe la operación del CF y el EZF hasta que la ventana de datos se llena con sólo información del estado de falla.
6. El EZF programado en el relevador, puede tener una o dos RNA.
7. Se adiciona un contador de seguridad, ajustado a tres conteos, en el CF y el EZF.
8. Las señales incrementales de entrada al CF provenientes del ERD Delta, se desacoplan con los modos de propagación. Los patrones de entrada a las RNA son formados de las señales desacopladas con los modos de propagación.
9. Se restringe la operación del relevador a un ciclo de frecuencia fundamental. Si este elemento instantáneo no opera durante el primer ciclo posterior al inicio de la falla, se bloquea su operación.

6.3 Metodología de pruebas

En esta tesis se denomina prueba en tiempo real a la simulación de una falla en MATLAB, el procesamiento de las señales de falla en el prototipo de relevador en MATLAB y, como resultado, la emisión de señales de salida del relevador.

La Tabla 6.1 muestra los parámetros utilizados en las pruebas realizadas al relevador para caracterizar su comportamiento.

TABLA 6.1 CONDICIONES DE FALLA APLICADAS EN LAS PRUEBAS.

	Parámetros
Resistencias de falla (ohms)	0, 50, 100
Relación impedancia de sistema / impedancia de línea (SIR)	0.7, 1.5
Localizaciones de fallas internas, p.u. de la longitud de la línea	0.01, 0.1, 0.85, 0.9, 0.99
Localizaciones de fallas externas, p.u. de la longitud de la línea	-0.1, -0.01, 1.01, 1.1
Tipos de fallas	ABC, AB, BC, AC, ABT, BCT, ACT, AT, BT, CT
Ángulos de inserción de falla (grados)	0, 36, 72, 108, 144, 188, 216, 252

Al prototipo programado se le aplicaron 2,900 pruebas distintas, las cuales se obtienen de combinar los parámetros presentados en la Tabla 6.1. Se puede observar que se asignaron valores a la localización de las fallas que representan pruebas exigentes al prototipo de relevador, en particular, a los elementos EZF.

Del total de eventos que se utilizaron en las pruebas, se incluyeron 1,340 fallas internas y 1,340 fallas externas, repartidas entre fallas hacia atrás y fallas en la línea adyacente hacia delante; se incluyeron también 50 maniobras de apertura de interruptores y 50 de cierre de interruptores.

La tarea del relevador se vería facilitada si se utilizaran solo valores intermedios de los dados en la Tabla 6.1. Sin embargo, el objetivo de las pruebas es caracterizar el desempeño ante condiciones críticas. Con esa intención, se incluyeron en las pruebas del prototipo cinco fallas de alta impedancia (con 100 ohms de resistencia de falla) y cinco fallas con arco eléctrico, en que la resistencia de falla es variable con el tiempo.

6.4 Análisis de operación del EZF

Se estableció en el Capítulo 2 la necesidad de una herramienta que permitiera analizar la operación de un relevador neuronal. En esta tesis se proporciona un procedimiento apropiado para el análisis de la operación del prototipo de relevador neuronal. Con fines de ilustración, a continuación se analizan los resultados que se obtienen de los dos EZF propuestos, para fallas internas y externas a la línea de transmisión protegida.

6.4.1 Ejemplos de operación del EZF

La Fig. 6.2a muestra el tipo de respuesta obtenido del EZF con una RNA y la Fig. 6.2b muestra el tipo de respuesta del EZF de dos RNA, cuando se tiene una falla interna. En el eje de ordenadas aparece el valor de salida *d(n)*, que se obtiene directamente de la clasificación de patrones con las RNA (variable binaria de valor +1 ó -1). En el eje de abscisas se representa el tiempo, medido en instantes de muestreo. Cada punto de las gráficas corresponde a una muestra. Con una frecuencia de muestreo de 64 muestras por ciclo, la separación entre muestras es 1/64 de ciclo, o 1/3840 segundos. En las figuras está indicado el inicio de la falla en la muestra 64. De acuerdo con la lógica de disparo diseñada, las primeras 16 salidas de la clasificación del EZF (1/4 de ciclo) no se utilizan. Esas salidas *d(n)* de la muestra 64 a la 80 son descartadas, porque se inhibe la clasificación de las RNA para evitar el problema de llenado de ventana de datos. Se habilita el procesamiento del EZF cuando las RNA procesan sólo información del estado de falla (muestra 81). Por ello, se observa en esos ejemplos que la salida de las dos variantes de EZF tiene un retardo de tiempo igual a un cuarto de ciclo de frecuencia fundamental. Los valores discretos de las señales de salida, son las señales resultantes de

la clasificación de los 48 patrones presentados a la entrada de las RNA, que corresponden a las muestras contenidas en 48 posiciones consecutivas de ventanas.

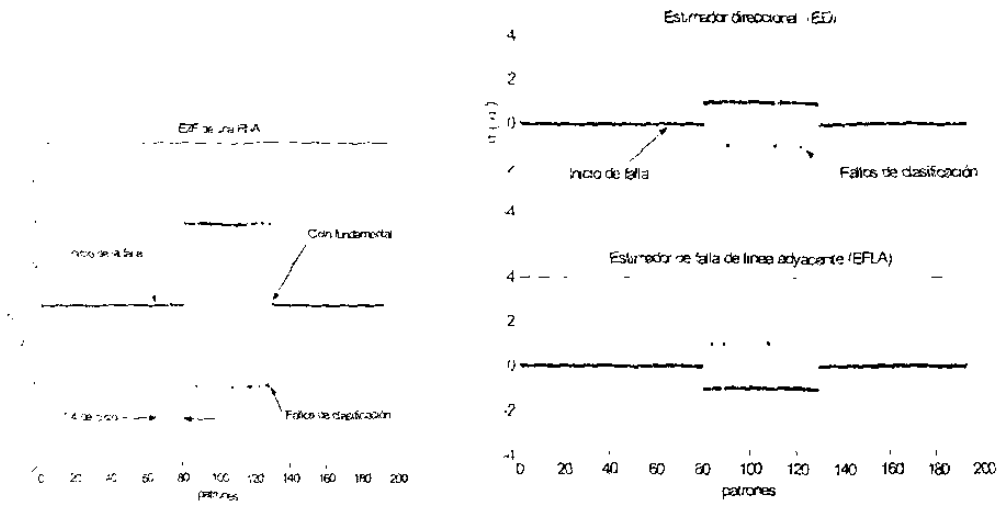

(a) (b)

Fig. 6.2 Operación de los EZF con una y dos RNA para una falla interna.

En la gráfica de operación del EZF de una neurona (Fig. 6.2a), se puede distinguir que los patrones de la falla interna se clasifican al valor +1, lo cual constituye una condición de disparo. Durante el ciclo en que el EZF permanece activado hay también algunos fallos de clasificación, que se tratarán más adelante. Con relación al resultado del EZF de dos RNA, se puede observar que, ante una falla interna, el estimador direccional (ED) da salidas de −1, indicativas de que la falla está en dirección hacia delante. El EFLA, por su parte, señaliza que los patrones no pertenecen a una falla en la línea adyacente (salida -1). De acuerdo con la lógica de disparo del EZF de dos RNA (Fig. 5.9), la condición que se muestra en la Fig. 6.2b genera una señal de disparo.

La Fig. 6.3 muestra la operación de los EZF con una y con dos RNA cuando se tiene presente una falla externa detrás del relevador.

Se puede observar en la Fig. 6.3a la respuesta del EZF con una RNA; su salida es, en general, igual a -1; eso indica que los patrones pertenecen a una condición de falla externa. Por otro lado, en la Fig. 6.3b se observa la salida del EZF de dos RNA; en este

caso el EZF opera de la siguiente manera; el EFLA reconoce que los patrones no pertenecen a un falla en la línea adyacente (salida –1), lo cual implica que la falla debe estar dentro de la zona protegida o por detrás del relevador; la falla externa por detrás del relevador se discrimina cuando el estimador direccional señaliza que la falla se observa en la dirección hacia atrás del relevador (salida -1).

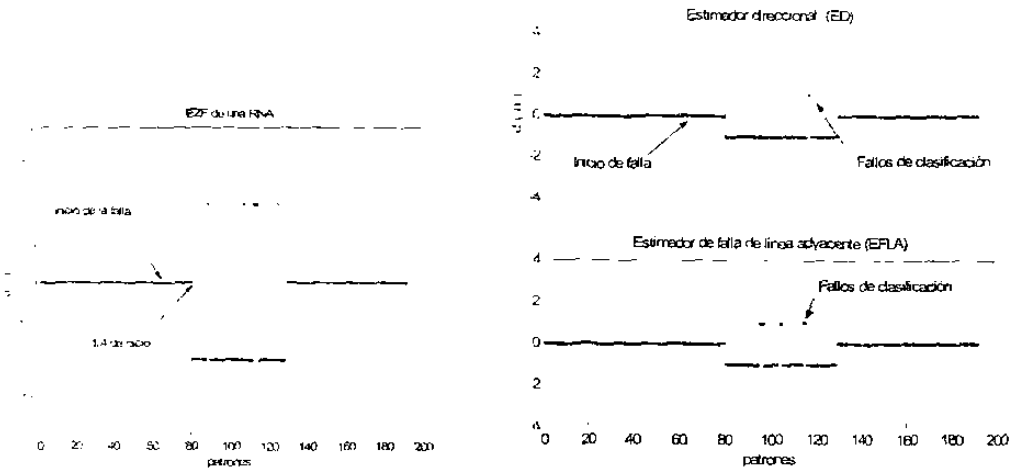

Fig. 6.3 Operación de los EZF con una y dos RNA para una falla detrás del relevador.

El tercer caso posible de operación de los EZF, una falla externa hacia adelante, se ilustra en la Fig. 6.4. La Fig. 6.4a muestra la respuesta del EZF de una RNA. La salida -1 indica falla externa.

En la Fig. 6.4b se muestra la salida del EZF de dos neuronas. En este caso el ED indica con una salida +1 que la falla ocurrió la en dirección hacia delante del relevador; simultáneamente, el EFLA señala con una salida +1 que la falla se localiza en la línea adyacente. De esta manera se establece que la falla es externa, y la lógica del EZF bloquea el disparo. El EZF de dos RNA tiene la ventaja adicional de informar sobre la ubicación de la falla.

En todos los casos de las figuras anteriores se observa la presencia de salidas erróneas, derivadas de fallos de clasificación. Para fallas internas, una salida errónea durante el ciclo en que está activo el EZF puede provocar su reposición, si ya emitió la señal de disparo. Para fallas externas, una salida errónea del EZF puede provocar un

disparo incorrecto. La solución a ambos problemas es añadir un contador de seguridad, que permita la emisión de una salida de disparo solo cuando se tienen dos o más (según su ajuste) pulsos de disparo consecutivos, y que permita la reposición del EZF solo cuando se tienen dos o más pulsos de reposición consectivos.

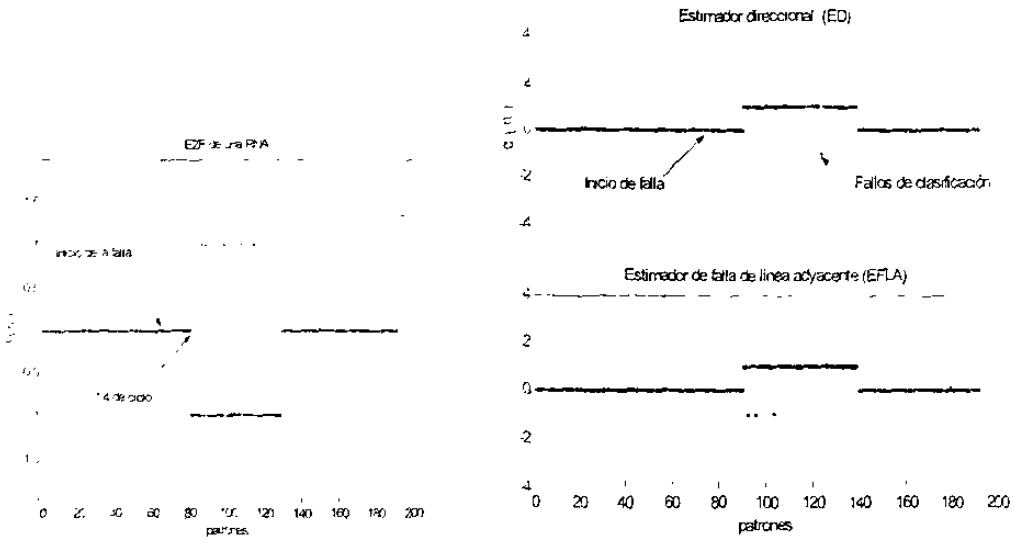

(a) (b)

Fig. 6.4 Operación de los EZF con una y dos RNA para una falla externa hacia adelante.

6.4.2 Efecto del contador de seguridad

A continuación se hace el análisis de varias fallas, con el objetivo de explicar la necesidad del contador de seguridad y evaluar su ajuste.

En la Fig. 6.5 se muestra la simulación de una falla sólida de la fase A a tierra. La falla está localizada dentro de la línea protegida a una distancia de 0.85 en p.u. de la longitud de la línea. La falla ocurre en el cruce por cero de la señal de voltaje. En la parte superior de la Fig. 6.5 se muestran las tres señales de voltaje y las tres señales de corriente. Se puede observar que la falla sólida que ocurre en el cruce por cero de la onda de voltaje no genera componentes transitorias de alta frecuencia. En la Fig. 6.5 se muestra también el resultado del reconocimiento de patrones del EZF de una RNA.

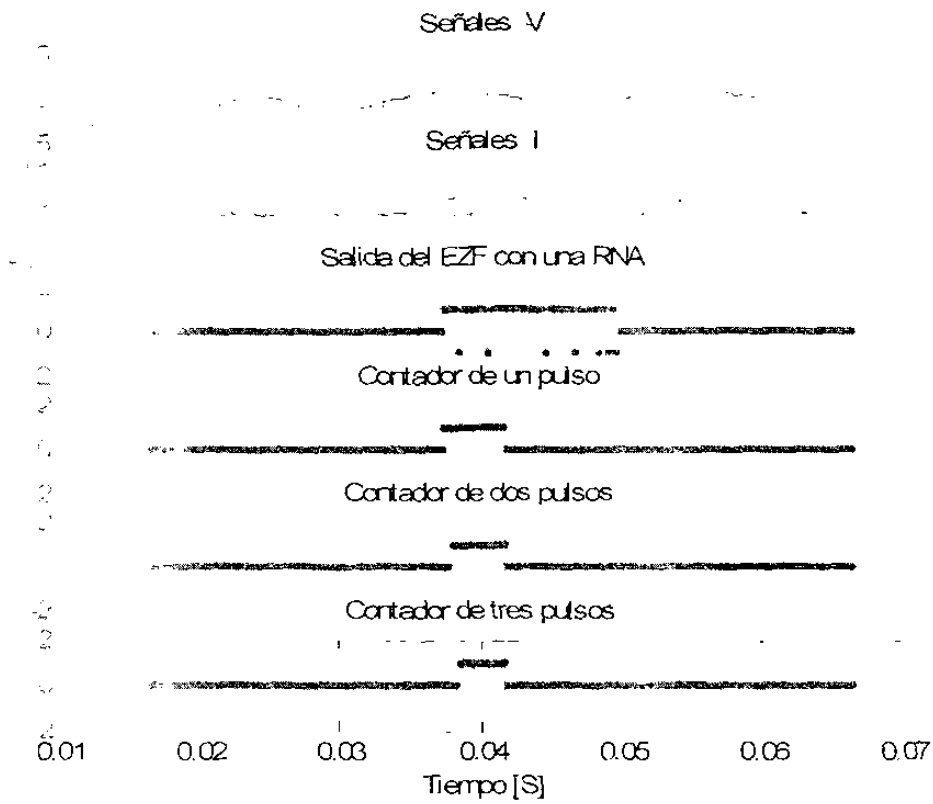

Fig. 6.5 Operación del EZF con una RNA para una falla sólida interna.

Puede observarse que el EZF de una neurona logra en general reconocer la presencia de una falla dentro de la zona de protección, al clasificar correctamente la mayoría de los patrones observados dentro del período de activación del EZF. Se puede observar también que para esta falla se tuvieron siete salidas incorrectas, que tienden a reposicionar al EZF.

En la parte inferior de la Fig. 6.5 se muestran tres alternativas de salidas de disparo del EZF de una RNA, resultantes de incluir un contador de seguridad ajustado a un pulso, dos pulsos o tres pulsos consecutivos. La operación que se muestra en las tres figuras correspondientes fue correcta. En esas figuras también se puede observar que las salidas de disparo son restringidas a una duración de un cuarto de ciclo, para evitar fallos de clasificación que pueden ocurrir hacia el final del intervalo en que están activos los EZF (últimas ventanas clasificadas).

La Fig. 6.6 muestra los resultados de una prueba realizada en que se aplicó una falla con resistencia de falla constante de 50 ohms. La falla se simuló detrás del relevador (en la localización -0.1 p.u.), y es una falla monofásica C-T. Puede observarse que, para esta falla hacia atras, el contador ajustado a un pulso genera un disparo incorrecto. Para esta falla el EZF de una RNA tiene un buen comportamiento cuando el contador está ajustado a dos o tres pulsos consecutivos.

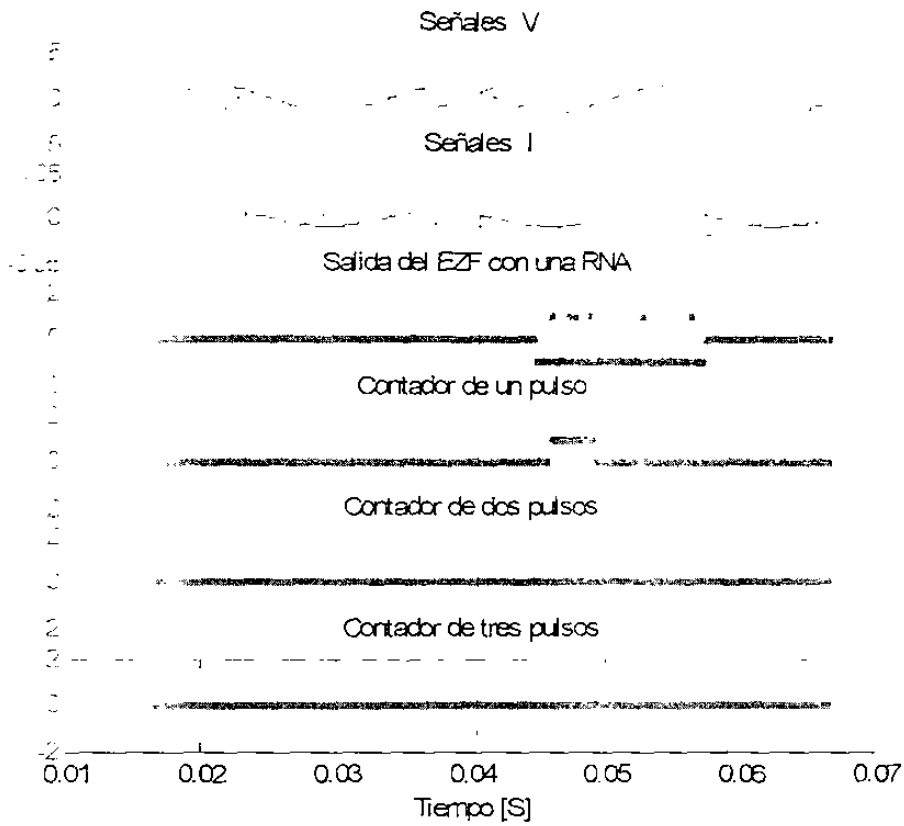

Fig. 6.6 Operacion del EZF con una RNA para una falla externa con resistencia

En la Fig. 6.7 se muestra la operación del EZF de dos RNA cuando se le aplico exactamente la misma falla de la prueba presentada en la Fig. 6.5. Las señales transitorias de voltaje y corriente son idénticas que las mostradas en la Fig. 6.5. La salida del EZF de dos RNA en este caso presentó menos fallos de clasificación que el EZF de una RNA. En esta prueba se tiene también una operación correcta con cualquiera de los tres ajustes del contador de seguridad.

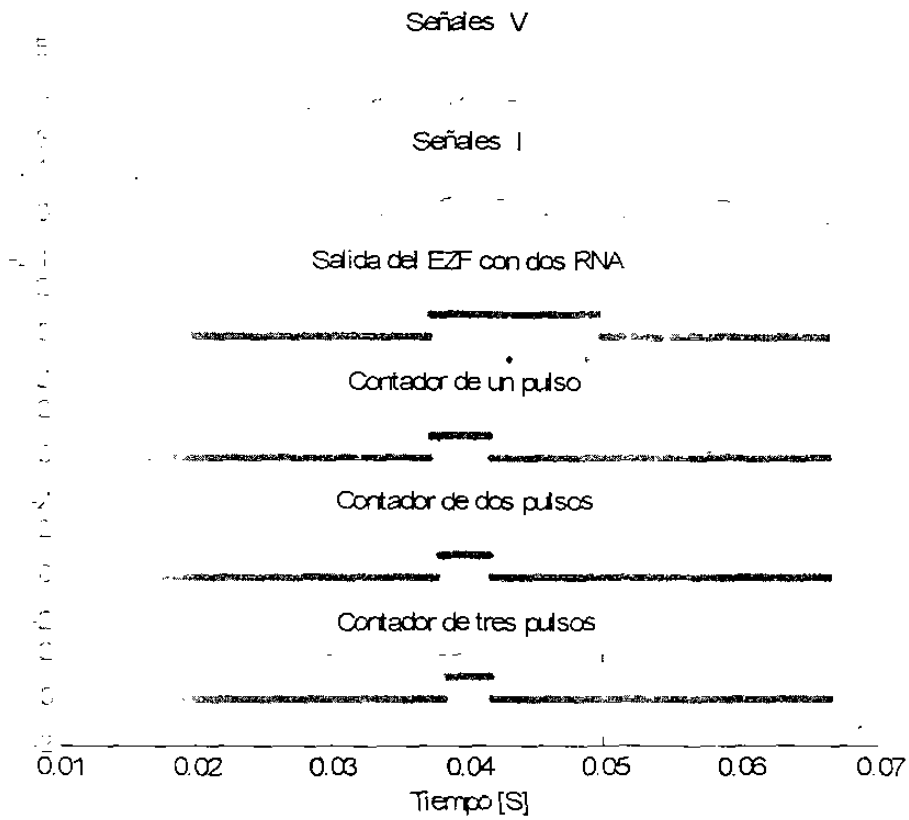

Fig. 6.7 Operación del EZF con dos RNA apara una falla sólida interna.

La Fig. 6.8 muestra una prueba realizada al EZF de dos RNA en que se aplicó una falla con resistencia de falla de 50 ohms. La falla se simula detrás del relevador (en -0.1 p.u.), y es también del tipo monofásico B-T. Nuevamente el EZF de dos RNA tiene menor número de fallos de clasificación que el EZF de una RNA. Sin embargo, si se utiliza el primer pulso de salida para el disparo, se genera una operación incorrecta. Ajustando el contador de seguridad en dos o tres pulsos, se filtra ese error de clasificación y se elimina el disparo incorrecto.

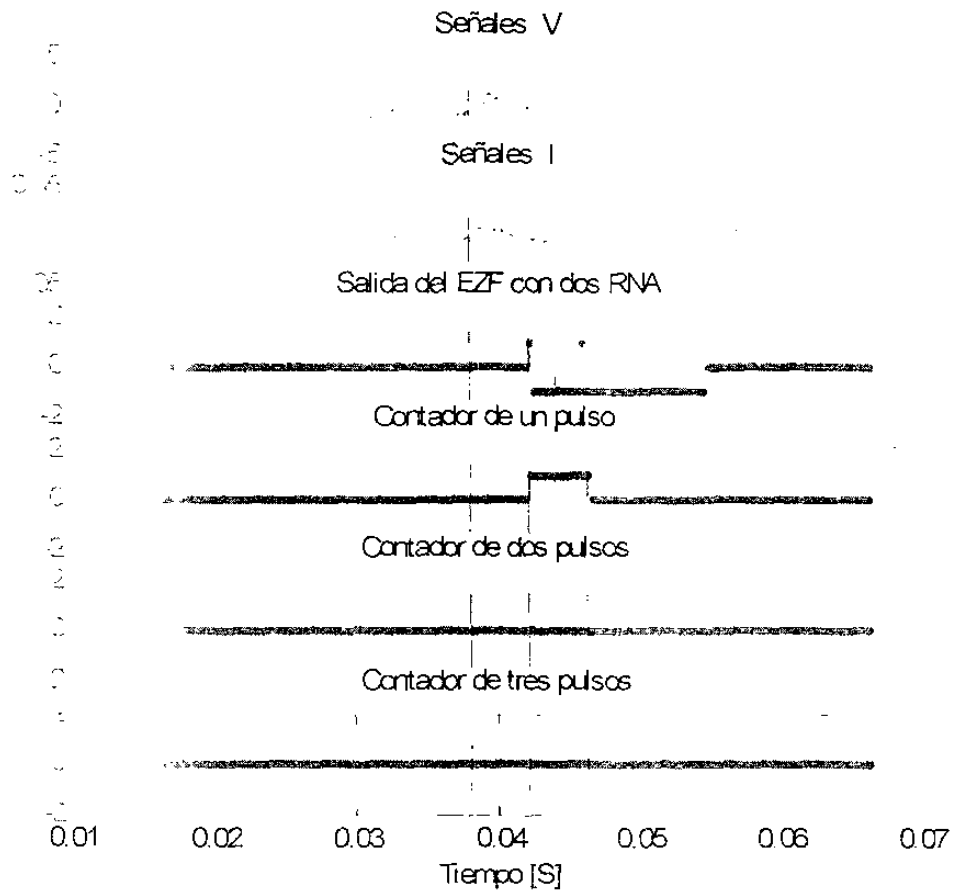

Fig. 6.8 Operación del EZF con dos RNA para una falla externa hacia atrás.

En la Fig. 6.9 se muestra el resultado de aplicar una falla con resistencia de falla de 100 ohms. La falla es interna y a una distancia de 0.9 p.u. La falla es del tipo B-C-T y ocurre a un ángulo de 128° con respecto al cruce por cero del voltaje de la fase A. Una falla de alta impedancia se caracteriza porque las señales de voltaje tienen poco abatimiento y la corriente aumenta poco en magnitud. La operación del relevador que se muestra en la Fig. 6.9 es correcta para cualquier ajuste del contador. Se observa que se presentaron seis fallos de reconocimiento de patrones tardíos, pero los contadores de seguridad filtraron correctamente la información.

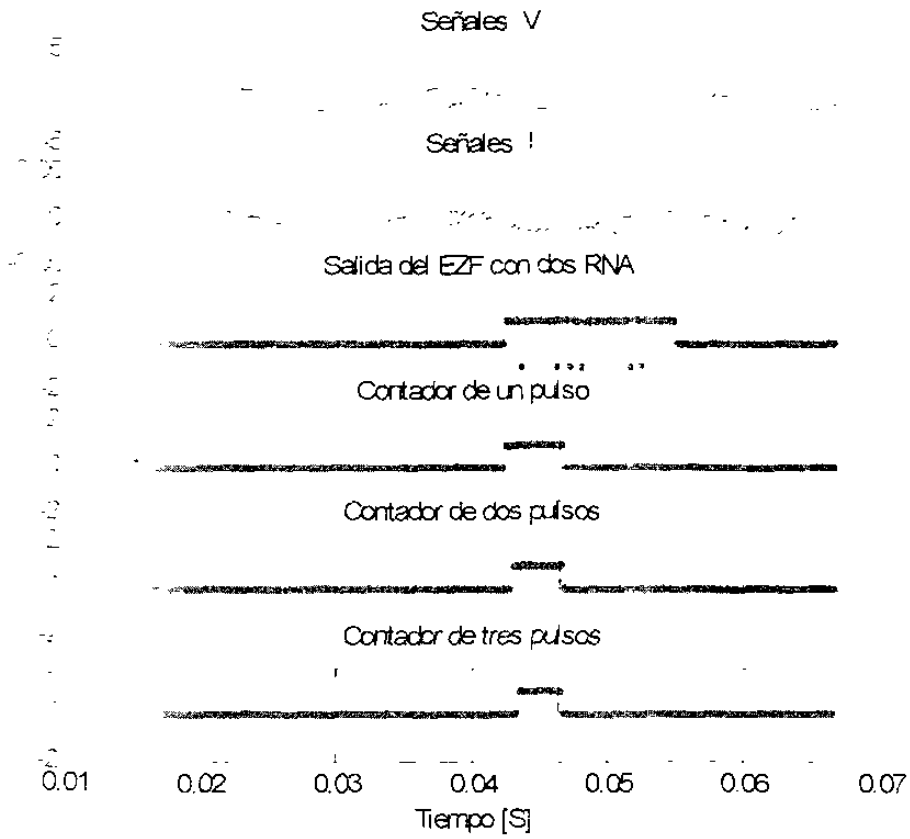

Fig. 6.9 Operación del EZF con dos RNA para una falla interna de alta impedancia.

En lineas de transmisión por lo general las fallas provocan arcos eléctricos. El arco eléctrico figura es una resistencia de falla de carácter no lineal y variable con el tiempo. En la Fig. 6.10 se muestra el resultado de aplicar una falla con arco eléctrico al prototipo de relevador. La falla es del tipo A-T y se ha simulado repitiendo tres datos de la prueba anterior. La resistencia de falla en este caso se modeló en la forma descrita en la Sección 3.4.6. Se puede observar que el EZF de dos RNA opera correctamente ante esta falla. Sin embargo, se aprecia que la variación de la resistencia de falla con el tiempo, da a lugar a un considerable numero de fallos de reconocimiento de patrones.

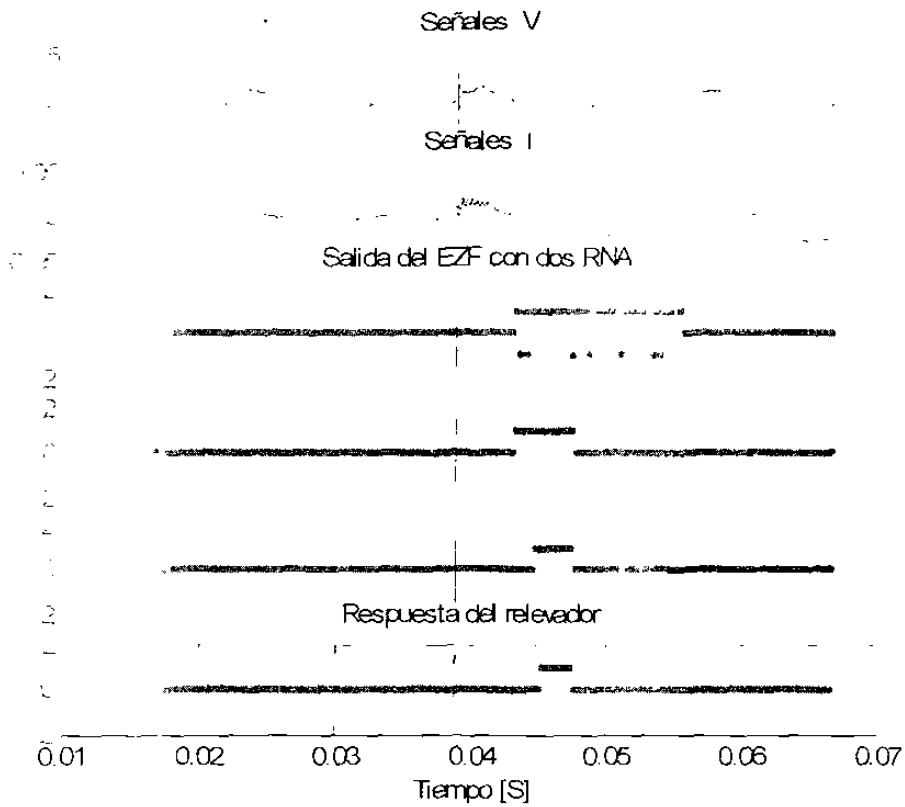

Fig. 6.10 Operación del EZF con dos RNA para una falla interna con arco eléctrico.

6.4.3 Estadísticas de operación del EZF con una RNA

Al prototipo de relevador se le aplicaron 2,900 fallas internas y externas. En la Tabla 6.2 se presentan los porcentajes de operaciones correctas y fallos de operación del EZF de una RNA cuando se le presentaron 1550 fallas internas, con los tres ajustes estudiados del contador de seguridad: uno, dos y tres pulsos consecutivos.

En la Tabla 6.2 se observa que el mejor desempeño se tiene con el contador de seguridad ajustado a tres pulsos positivos consecutivos, y es de un 93.9% de operaciones correctas para fallas en el 100% de la longitud de la línea. Este es un resultado aceptable, sobre todo teniendo en cuenta que se incluyeron en las pruebas a condiciones de fallas de alta impedancia y fallas con arco eléctrico. Muchas de las pruebas representaron fallas difíciles de detectar por las técnicas convencionales.

TABLA 6.2 DESEMPEÑO DEL EZF DE UNA RNA PARA FALLAS INTERNAS

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erroneas	% operaciones correctas	% fallos de operacion
Un pulso positivo	1550	1348	202	87.0	13.0
Dos pulsos consecutivos	1550	1379	171	89.1	10.9
Tres pulsos consecutivos	1550	1454	96	93.9	6.1

La Tabla 6.3 resume los resultados de las pruebas al EZF de una RNA para 1350 casos de fallas externas. Esas fallas externas se simularon en las dos líneas adyacentes a la línea protegida.

TABLA 6.3 DESEMPEÑO DEL EZF DE UNA RNA PARA FALLAS EXTERNAS

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erróneas	% operaciones correctas	% fallos de operación
Un pulso positivo	1350	1127	223	83.5	16.5
Dos pulsos consecutivos	1350	1202	148	88.9	11.1
Tres pulsos consecutivos	1350	1233	117	91.4	8.6

Los resultados que se muestran en la Tabla 6.3 demuestran que el EZF de una RNA no tiene suficiente seguridad para fallas externas. En el mejor de los casos, con el contador ajustado a tres pulsos, se logró un 91.4% de operaciones correctas. En estas pruebas se observó que la mayor parte de los fallos de operación corresponde a fallas en la línea adyacente hacia adelante.

6.4.4 Estadísticas de operación del EZF con dos RNA

En la Tabla 6.4 se presentan los resultados de las pruebas al EZF de dos RNA para 1550 fallas internas. Con esta variante de EZF, se eleva el desempeño del EZF ante fallas internas, de 93.9 a 99.1% de operaciones correctas, para un ajuste de tres pulsos en el contador.

TABLA 6.4 DESEMPEÑO DE ED-EFLA PARA FALLAS INTERNAS.

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erróneas	% operaciones correctas	% fallos de operacion
Un pulso positivo	1550	1421	129	91.7	8.3
Dos pulsos consecutivos	1550	1523	27	98.3	1.7
Tres pulsos consecutivos	1550	1536	14	99.1	0.9

La Tabla 6.5 muestra los resultados de la operación del EZF de dos RNA para 1350 fallas externas. Nuevamente se observa una mejoria en los resultados con respecto al caso del EZF con una RNA.

TABLA 6.5 DESEMPEÑO DE ED-EFLA PARA FALLAS EXTERNAS.

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erróneas	% operaciones correctas	% fallos de operación
Un pulso positivo	1350	1233	317	91.4	8.6
Dos pulsos consecutivos	1350	1313	237	97.3	2.7
Tres pulsos consecutivos	1350	1325	225	98.2	1.8

De las 2900 pruebas realizadas, y de los resultados que se resumen en las Tablas 6.2 a 6.5, puede concluirse lo siguiente:

1. Se confirmo que excluir del entrenamiento y de la operacion en tiempo real los patrones de la transición del llenado de ventana eleva en forma considerable la calidad de la clasificación. Los patrones que contienen solo información del estado de falla son mas fácilmente reconocibles por las RNA.

2. La adición de un contador de seguridad mejora considerablemente el desempeño del EZF. Con las pruebas se estableció que el contador de tres pulsos es el más apropiado para esta aplicacion. El retardo de tiempo de operación resultante de este contador es de solo dos periodos de muestreo (0.52 milisegundos para 64 muestras por ciclo).

3. El mayor número de errores de clasificación ocurre hacia el final del tiempo de activación del EZF. Por tanto, se decidió reducir ese tiempo al primer cuarto de ciclo en que se dispone de información pura del estado de falla.

4. El EZF de dos RNA tiene mejor desempeño que el de una RNA. La adición de la RNA para discriminar fallas en la línea adyacente (EFLA), redujo el grado de complejidad de la clasificación.

5. Ambos tipos de EZF operan mejor para fallas internas, que para fallas externas. Esto implica que el elemento neuronal instantáneo tiene mayor dependabilidad que seguridad.

6. Las fallas con arco eléctrico generan patrones difíciles de reconocer por las RNA. El contador ajustado a tres pulsos dio buenos resultados para las fallas evaluadas, pero es necesario continuar estudiando en el futuro este tipo de fallas, y realizar pruebas al EZF con otras fallas complejas.

6.5 Ejemplos de operación del CF

A manera de ilustración, la Fig. 6.11 muestra las salidas que se obtienen del elemento CF para una falla entre las fases B, C y tierra. Se ha explicado que este elemento instantáneo está formado por diez RNA procesando simultaneamente el mismo patrón de entrada. En la gráfica se muestran las diez señales de tipo binario que se obtienen para esta falla BCT. Cada una de esas señales corresponde a la salida de una RNA.

En la Fig. 6.11 no se indica el inicio de la falla, pero en el CF también se aplica la logica que elimina las primeras 16 salidas de la clasificacion Por tanto, el CF también tiene un retardo de tiempo igual a un cuarto de ciclo de frecuencia fundamental.

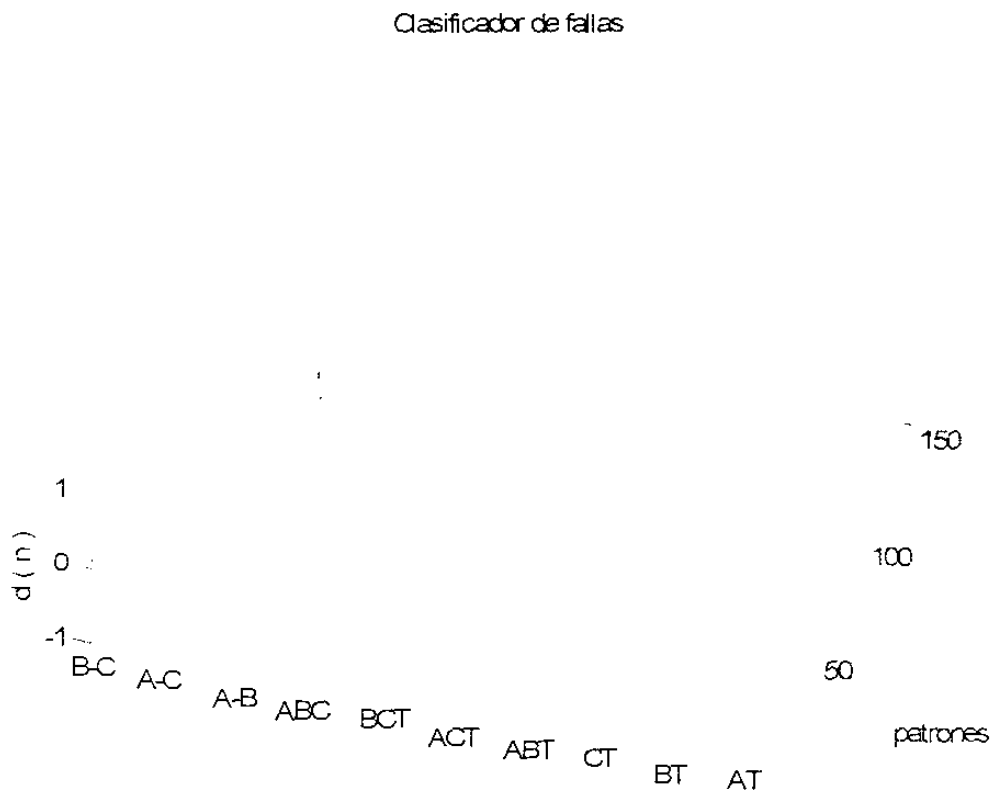

Fig. 6.11 Operación del CF para una falla BCT.

Se puede observar en la Fig. 6.11 que a la salida del CF se tienen diez señales de tipo binario. También se observan los disparos eventuales que representan fallos de clasificación. Ya fue demostrado que la adición del contador de seguridad de tres pulsos en el EZF resuelve el problema de los fallos de clasificación.

La Fig. 6.12 muestra el resultado de la operación del elemento CF para la misma falla de la Fig. 6.11. La primera linea de la Fig. 6.12 representa la salida de la RNA correspondiente a la falla en cuestión (BCT). Las lineas 2, 3 y 4 muestran las salidas de disparo monopolar del relevador (fases A, B y C respectivamente). La linea 5 corresponde a la salida de disparo tripolar del relevador neuronal. En esta figura se puede

ver también el efecto del contador de seguridad. Puede observarse que la operacion es correcta: se emite una salida de disparo tripolar para esta falla bifásica a tierra.

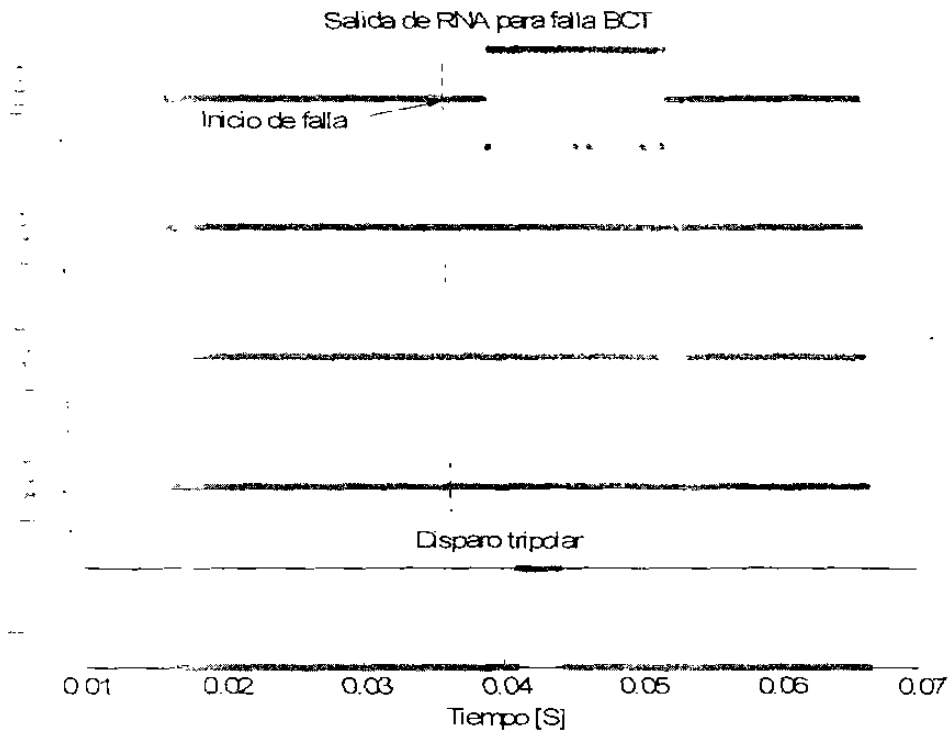

Fig. 6.12 Salidas de disparo del relevador para una falla BCT

La Fig. 6.13 muestra el resultado que se obtiene de aplicar al relevador una falla monofásica a tierra en la fase C. Se muestra la salida de la RNA del elemento CT, que clasifica correctamente el tipo de falla. Como resultado, el relevador emite una señal de disparo monopolar del polo C del interruptor.

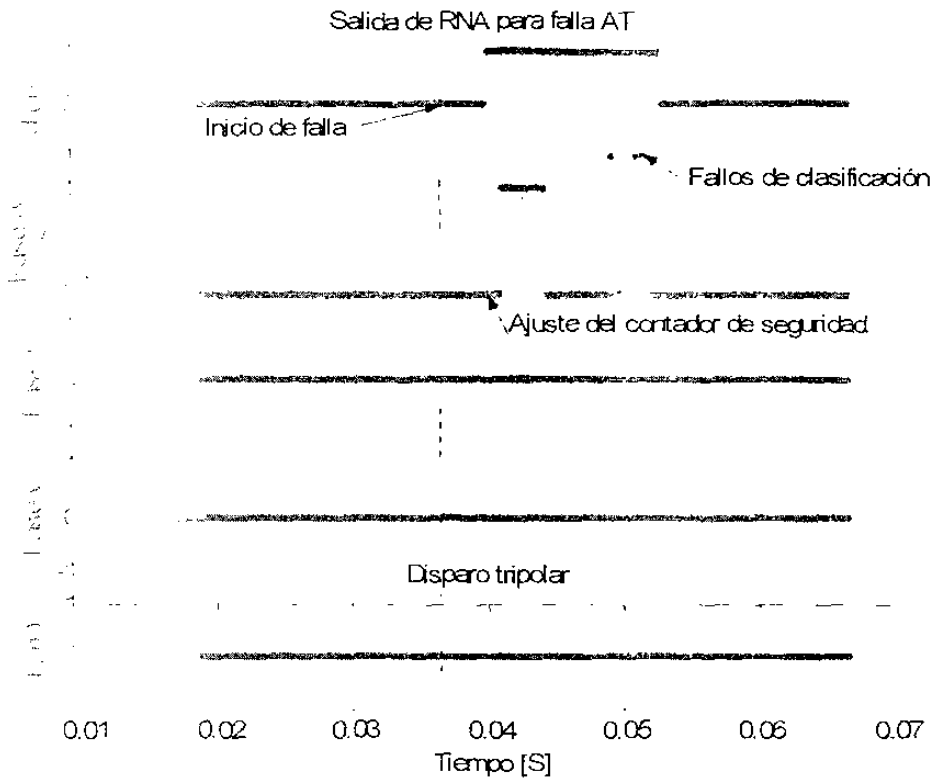

Fig. 6.13 Salidas de disparo del relevador para una falla AT

6.6 Estadísticas de operación del CF

En la Tabla 6.6 se presentan los resultados de las pruebas al CF, en que se le aplicaron 721 fallas monofásicas. Los resultados son excelentes para el CF con el contador ajustado a tres pulsos.

TABLA 6.6 DESEMPEÑO DEL CF PARA FALLAS MONOFÁSICAS.

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erróneas	% operaciones correctas	% fallos de operación
Un pulso positivo	721	672	49	93.2	6.8
Dos pulsos positivos	721	710	11	98.5	1.5
Tres pulsos positivos	721	720	1	99.9	0.1

La Tabla 6.7 muestra los resultados de la operación del CF para 721 fallas no monofásicas. También se logran buenos resultados en la clasificación con el contador ajustado a tres pulsos.

TABLA 6.7 DESEMPEÑO DEL CF PARA FALLAS NO MONOFÁSICAS.

	Resultados				
	Casos de prueba	# salidas correctas	# salidas erróneas	% operaciones correctas	% fallos de operación
Un pulso positivo	721	679	42	94.2	5.8
Dos pulsos positivos	721	697	24	96.8	3.2
Tres pulsos positivos	721	700	21	97.1	2.9

De las 1442 pruebas realizadas y de los resultados que se resumen en las Tablas 6.6 y 6.7, puede concluirse lo siguiente:

1. Las RNA reconocen debidamente los patrones de fallas monofásicas. Se tuvo un 99.9% de operaciones correctas para estas fallas, lo cual es un indicativo del excelente desempeño integrado del ERD delta-modal. Los resultados para fallas no monofásicas son también aceptables (un 97.1% de operaciones correctas).
2. La adición de un contador de seguridad mejora el desempeño del CF. Se recomienda ajustar el contador en tres pulsos para esta aplicación.

Las pruebas realizadas al CF incluyeron solo condiciones de fallas. Las maniobras de interruptores en las líneas no fueron incluidas en las pruebas, pero se estableció la necesidad de utilizar un elemento DF que discrimine entre fallas y otras condiciones operativas del sistema de potencia.

6.7 Conclusiones del capítulo

En este capítulo se desarrolló y programó en MATLAB un prototipo de relevador de protección de líneas de transmisión. Se trata de un elemento instantáneo, destinado a un esquema de protección piloto por comparación direccional, o a la primera zona de un

relevador de distancia. Como elemento de primera zona, tiene la ventaja de lograr la protección instantanea en el 100% de la linea protegida sin canal de comunicaciones.

Las caracteristicas fundamentales del prototipo son. frecuencia de muestreo de 64 muestras por ciclo, ventana de datos de un cuarto de ciclo; el CF y el EZF se activan cuando la ventana de datos se llena con solo información de falla; el EZF tiene un ERD Delta para el pre-procesamiento de señales; el CF tiene un ERD Delta-Modal; el CF y el EZF tienen un contador de seguridad, ajustado a tres conteos.

En este capitulo se reportan los resultados de la aplicación de 2,900 fallas al prototipo de relevador en MATLAB para caracterizar su desempeño de manera integrada, asi como evaluar y comparar dos tipos de EZF, uno con una RNA, y otro con dos RNA. De estas pruebas se concluye que. a) La adición de un contador de seguridad mejora considerablemente el desempeño del EZF. El contador de tres pulsos es el más apropiado para esta aplicación b) El EZF de dos RNA tiene mejor desempeño que el de una RNA c) El EZF de dos RNA clasificó bien el 99.1% de las fallas internas y el 98.2% de las fallas externas aplicadas.

Para probar el desempeño del CF se aplicaron al relevador 1442 fallas (721 monofásicas y 721 de los demás tipos). Se concluye que: a) La adición de un contador de seguridad mejora el desempeño del CF. Se recomienda ajustar el contador en tres pulsos para esta aplicación. b) Las RNA reconocen muy bien los patrones de fallas monofásicas. Se tuvo un 99.9% de operaciones correctas para estas fallas. c) El DF clasificó bien el 97.1% de las fallas no monofásicas

Los resultados alcanzados son muy promisorios y representan un avance significativo con relación a los trabajos sobre el tema reportados hasta la fecha.

El diseño de relevadores de protección en ambiente de MATLAB es de gran utilidad, pues permite hacer pruebas exhaustivas antes de contar con un prototipo fisico del relevador.

CAPÍTULO VII

CONCLUSIONES, APORTACIONES Y RECOMENDACIONES PARA TRABAJOS FUTUROS

7.1 Conclusiones generales

1. Se estudiaron los problemas típicos de los relevadores de distancia y de onda viajera. Los relevadores de distancia tienen parámetros de ajuste fijos, lo que dificulta cumplir con los requerimientos de protección en condiciones de operación variable en el SEP. Una solución a este problema es la implementación de una lógica inherentemente adaptiva basada en la utilización de las RNA.

2. Se estableció la estructura del relevador neuronal a utilizar como elemento instantáneo (primera zona) de un relevador de distancia. La estructura del relevador neuronal se compone de módulos independientes para las tareas de detección de fallas (DF), clasificación de fallas (CF) y estimación de zona de falla (EZF) basados en RNA. Los elementos de respaldo y para otras funciones no son objeto de estudio de esta tesis.

3. Se elaboró un programa de simulación para generar las señales de prueba del prototipo de relevador desarrollado en esta tesis. Las señales transitorias de condiciones de falla y otras perturbaciones del sistema de potencia son calculadas con la técnica del dominio de la frecuencia. De esta forma se logra incluir el efecto de la variación frecuencial en la propagación de las ondas viajeras. También se tienen bajo control el ruido numérico y los valores de las variables aleatorias con que se lleva a cabo la simulación. De la evaluación realizada se concluye que se cuenta con un programa que produce mejores simulaciones que las que se generan con los programas del dominio del tiempo.

4. El programa de simulación desarrollado incluye modelos de linea de transmisión uniforme para estudios de propagación de ondas viajeras. También contiene los modelos de fallas con resistencia constante, fallas con arco eléctrico, e interruptores. Estos modelos se llevan a la formulación nodal que fue resuelta mediante una técnica del dominio de la frecuencia basada en la aplicación de la Transformada Numérica de Laplace, la teoría modal y el principio de superposición.

5. La teoría modal permite explicar el mecanismo de propagación de las ondas viajeras a través de los sistemas de transmisión polifásicos. Se demostró en la tesis que los modos naturales de propagación de la línea son una herramienta de análisis importante para reconocer rasgos de las señales y también sirven para producir el desacoplamiento magnético entre fases.

6. Se estudió el procesamiento digital de señales de un relevador neuronal. Se explicaron los pasos para obtener los patrones de entrenamiento a partir de las señales crudas. En caso que las RNA procesan muestras crudas, formadas de ventanas de datos de igual longitud, no se eliminan las componentes transitorias de alta frecuencia que deja pasar el filtro antialiasing. Esto dificulta el proceso de aprendizaje de las RNA.

7. Con el fin de obtener una representación de patrón que resulte más simple de clasificar por las redes de neuronas, se incluyó un elemento extractor de rasgos distintivos (ERD) de las señales. Se demostró con ejemplos que los ERD, al operar sobre las muestras crudas, producen una representación de patrón más compacta y simple de mapear. En la tesis se desarrollaron y evaluaron varios tipos de ERD. Uno de ellos se basa en un filtro Delta, otro se basa en la convolución con la onduleta Daubechies 2, otro es un filtro de Fourier, y otro se basa en el desacoplamiento de señales con los modos de propagación; se evaluaron también ERD formados por combinaciones de los anteriores.

8. El desarrollo de los ERD incluye una implementación a nivel de simulación digital en MATLAB. Se utilizaron las señales generadas con el simulador *digital para* reproducir ejemplos de de patrones a la salida del ERD. Como resultado de la aplicación de los ERD y de seguir una metodología especialmente desarrollada para formar bancos de patrones, se tiene información apropiada para entrenar las RNA. Se

hicieron pruebas de sensibilidad, cambiando los valores de las variables aleatorias, con el fin de evaluar la información que se obtiene de los ERD con ventanas de datos de longitud menor que un ciclo de frecuencia fundamental.

9. Se estableció la estructura general del tipo de RNA a utilizar en el relevador neuronal. Se seleccionó una red tipo perceptrón multicapa, con todas sus neuronas interconectadas, y entrenadas con el algoritmo de retropropagación del error (BP). Las neuronas de la capa de salida tienen una función de activación Signo, y las restantes neuronas tienen funciones de activación Sigmoide o Tangente Hiperbólica.

10. Se estableció una metodología de diseño de las estructuras de RNA a utilizar en el relevador. Se comienza con una RNA de una capa oculta y un número alto de neuronas, que se entrena por BP con regularización. Se eliminan las neuronas con pesos muy bajos, y se define el número N de neuronas útiles. Se entrena esa red por BP (Levemberg-Marquard) y se hacen pruebas de desempeño a esa RNA y a otros con números de neuronas cercanos a N. Si el resultado es bueno, se selecciona esa RNA; si no, se repite el proceso con RNA de dos o más capas ocultas, hasta encontrar la adecuada.

11. Se investigó el posible desarrollo de un detector neuronal de fallas trifásico. Se estudiaron 22 posibles estructuras de RNA, con combinaciones de las siguientes variables: a) Frecuencias de muestreo de 16 y 64 muestras por ciclo. b) Ventanas de datos de 1/4, 5/16, 1/2 y 1 ciclo. c) Señales de entrada sin filtrar (crudas) o pre-procesadas en un extractor de rasgos distintivos (ERD). d) Tipos de ERD: Filtro Delta, ERD Modal, Onduleta Daubechies 2, combinaciones de estas, y filtros de extracción de fasores. De las pruebas realizadas se concluyó que ninguna de estas alternativas es apropiada para un detector de fallas trifásico. Se utilizará en el relevador neuronal un detector de fallas tradicional basado en el filtro Delta. Se recomienda profundizar en el futuro el estudio de los detectores de fallas monofásicos, de los que se ha reportado un buen desempeño en trabajos anteriores.

12. Se estudiaron varias estructuras de RNA para realizar la función de clasificación de fallas. Se encontró que una red con 7 neuronas de entrada, 3 en la capa oculta y una de salida cumple bien esta función, cuando es precedida por un extractor de rasgos

distintivos de tipo modal. Esta RNA tiene buen desempeño incluso para 16 muestras por ciclo.

13. Se investigaron dos alternativas de estimadores de zona de falla neuronales. En la primera alternativa, una única red de neuronas fue entrenada para discriminar entre fallas en el 100% de la línea protegida, y fallas en otras líneas. Se añadieron condiciones de no falla a los patrones de entrenamiento. Los mejores resultados se obtuvieron con una RNA con 10 neuronas de entrada, 7 en la primera capa oculta, 3 en la segunda y una de salida, precedida por un extractor de rasgos distintivos tipo Delta. La segunda alternativa consiste en separar la estimación de zona de falla en dos funciones, un estimador direccional (ED), y un estimador de fallas en líneas adyacentes (EFLA). Para ambas funciones resultó adecuada una RNA con 16 neuronas de entrada, 9 en la primera capa oculta, 4 en la segunda y una de salida, precedida por un extractor de rasgos distintivos tipo Delta.

14. Se desarrolló y programó en MATLAB un prototipo de relevador de protección de líneas de transmisión. Se trata de un elemento instantáneo, destinado a un esquema de protección piloto por comparación direccional, o a la primera zona de un relevador de distancia. Como elemento de primera zona, tiene la ventaja de lograr la protección instantánea en el 100% de la línea protegida sin canal de comunicaciones. Las características fundamentales del prototipo son: frecuencia de muestreo de 64 muestras por ciclo; ventana de datos de un cuarto de ciclo; el CF y el EZF se activan cuando la ventana de datos se llena con solo información de falla; el EZF tiene un ERD Delta para el pre-procesamiento de señales; el CF tiene un ERD Delta-Modal; el CF y el EZF tienen un contador de seguridad, ajustado a tres conteos.

15. Se aplicaron 2.900 fallas al prototipo de relevador en MATLAB para evaluar y comparar dos tipos de EZF, uno con una RNA, y otro con dos RNA. De estas pruebas se concluye que: a) La adición de un contador de seguridad mejora considerablemente el desempeño del EZF. El contador de tres pulsos es el más apropiado para esta aplicación. b) El EZF de dos RNA tiene mejor desempeño que el de una RNA. c) El EZF de dos RNA clasificó bien el 99.1% de las fallas internas y el 98.2% de las fallas externas aplicadas.

16. Se aplicaron 1442 fallas al prototipo para evaluar el desempeño del CF. Se concluye que: a) La adición de un contador de seguridad mejora el desempeño del CF. Se recomienda ajustar el contador en tres pulsos para esta aplicación. b) Las RNA reconocen muy bien los patrones de fallas monofásicas. Se tuvo un 99.9% de operaciones correctas para estas fallas. c) El DF clasificó bien el 97.1% de las fallas no monofásicas.

17. Los resultados alcanzados son muy promisorios y representan un avance significativo con relación a los trabajos sobre el tema reportados hasta la fecha.

7.2 Aportaciones

1. Se elaboró un programa de simulación para generar las señales de prueba del prototipo de relevador desarrollado en esta tesis. El programa se basa en técnicas del dominio de la frecuencia, y produce mejores simulaciones que las que se generan con los programas del dominio del tiempo.

2. Se desarrolló una estructura de relevador neuronal sin pre-procesamiento de señales y otra en que se incluyó un elemento extractor de rasgos distintivos (ERD). Ambas estructuras utilizan un principio basado en el reconocimiento de patrones mediante redes de neuronas artificiales.

3. En la estructura con ERD se prescindió del cálculo de los fasores. Se desarrollo un método novedoso de procesamiento de señales que, en un tiempo reducido, hace la extracción de patrones indicadores de las condiciones de falla en la línea de transmisión.

4. Se desarrolló una metodología para diseñar RNA que reduce el grado de heurística del proceso de diseño. Con esa metodología se establece la estructura de RNA a utilizar para cada bloque funcional, y se asegura la convergencia del algoritmo BP en el proceso de entrenamiento de las RNA.

5. La formulación matemática de las RNA del tipo perceptrón multicapa requiere una representación del conocimiento dada con entradas y salidas en forma de vectores; estos vectores se organizan en bancos de patrones. En esta tesis se crearon bancos de

patrones que representan un gran número de escenarios operativos del SEP; esos bancos son aplicables a trabajos futuros de otros grupos de investigadores en esta área, y constituyen por sí mismos un aporte de la tesis.

6. Se hace en la tesis la fundamentación teórica de los elementos instantáneos CF y EZF del relevador neuronal. La tarea de CF se solucionó con RNA que reconocen los patrones que se obtienen del desacoplamiento de señales con los modos de propagación de la línea de transmisión. Por otro lado, la tarea de EZF se resolvió reconociendo los patrones derivados de las magnitudes incrementales de las señales de entrada al relevador.

7. Se propuso una nueva variante de esquema de protección no comunicado basado en un EZF con dos RNA. Una RNA logra la discriminación direccional (elemento direccional, ED); la otra RNA se utiliza para discriminar fallas en la línea adyacente hacia adelante. Ese elemento de fallas en líneas adyacentes, EFLA, constituye un nuevo tipo de elemento, que equivale a un elemento direccional trasladado de manera virtual al nodo opuesto a la ubicación del relevador. El resultado, un elemento que brinda protección instantánea al 100% de la línea protegida sin canal de comunicaciones, es otro aporte de esta tesis.

8. Se desarrolló un prototipo de relevador de ultra-alta velocidad, programado en MATLAB. El prototipo incluye las RNA que realizan las distintas funciones de protección, y la lógica de disparo. Las pruebas realizadas al prototipo de relevador neuronal demostraron que el principio aplicado tiene validez

7.3 Recomendaciones para trabajos futuros

1. En esta tesis se hizo una revisión de las técnicas de procesamiento de señales a utilizar en el relevador neuronal. Se evaluaron distintos ERD, pero no se profundizó en la aplicación de las onduletas, debido a que, para las frecuencias de muestreo consideradas, su desempeño fue pobre. Sin embargo, el filtrado basado en onduletas puede ser apropiado en este tipo de aplicaciones, si la frecuencia de muestreo es más alta. Se recomienda, por tanto, investigar el efecto de manejar un número mayor de muestras por ciclo de las señales de entrada al relevador, e investigar con mayor

profundidad el posible uso de onduletas como ERD, con el objetivo de mejorar los procesos de reconocimiento de patrones.

2. Se recomienda estudiar el comportamiento del prototipo de elemento instantáneo de protección en líneas con distintas configuraciones y niveles de voltaje. Con ello se puede conocer la robustez de los ajustes resultantes de entrenar las RNA para un sistema de potencia específico. El valor práctico de este estudio es definir si el elemento neuronal debe ser entrenado especialmente para la línea y sistema protegidos, o puede tener ajustes de fábrica. Dependiendo del resultado de este estudio, puede ser necesario desarrollar un software de entrenamiento del relevador neuronal.

3. El diseño del relevador neuronal ha sido realizado bajo el supuesto de que se dispone de transductores con características cercanas a las ideales. En realidad, las fallas provocan saturación de los transformadores de corriente y un comportamiento transitorio deficiente de los divisores capacitivos de potencial, que afectan la respuesta de los relevadores tradicionales. Es recomendable estudiar el efecto que produce este ruido de estado transitorio de los transductores de corriente y potencial sobre los algoritmos neuronales.

4. En el programa de simulación desarrollado en este este trabajo de tesis se incluyeron modelos de elementos no comunes, como son los dispositivos FACTS (incluyendo los capacitores de compensación serie), y los limitadores de corriente de falla, que tienen un fuerte impacto sobre el desempeño de los relevadores tradicionales. No fue posible estudiar a fondo el efecto de estos elementos sobre el relevador neuronal propuesto en la tesis. Se recomienda abordar este estudio en el futuro.

5. En esta tesis se hizo énfasis en el desarrollo de un elemento que brinda protección instantánea en el 100% de la línea protegida, sin canal de comunicaciones. Sin embargo, el principio es también utilizable cuando se dispone de un canal de comunicaciones, y permite conformar una protección piloto por comparación direccional con lógica de disparo o de bloqueo. Se recomienda estudiar esta alternativa en una siguiente etapa de investigación. Se recomienda también completar

la lógica del relevador, para incluir las distintas zonas temporizadas de protección de distancia.

6. Los relevadores digitales modernos tienen algoritmos que permiten resolver diversas tareas adicionales a las de protección, tales como control, medición, supervisión, comunicaciones y autodiagnóstico. Estos algoritmos no han sido tema de estudio en esta tesis. Es, por tanto, recomendable trabajar en la integración de estos algoritmos al futuro relevador neuronal.

7. Por los resultados alcanzados en esta tesis, es también recomendable probar este mismo principio en otros elementos del sistema eléctrico de potencia. Ya se han reportado investigaciones que abordan problemas similares en transformadores. La metodología que se reportó en esta tesis para diseñar las RNA puede ser adaptada para esos otros problemas de protección.

REFERENCIAS

[1]. Adamiak M., Alexander G., and Premerlani W., "Advancements in adaptive algorithms for secure high speed distance protection", *Memoria Técnica del III Simposio Iberoamericano sobre Protección de Sistemas Eléctricos de Potencia*. Monterrey, N.L., Mexico. Nov. de 1996.

[2]. Aggarwal R. and Song Y., "Tutorial: Artificial Neural Networks in power systems: Part 1, Part 2 and Part 3", *Power Engineering Journal*, IEEE, December 1998

[3]. Aggarwal R., Xuan Q.Y., Dunn R.W., Johns A.T., and Bennet A., "A novel fault classification technique for double-circuit lines based on a combined unsupervised supervised neural network", *IEEE Trans. PWRD*, Vol. 14, N° 4, October 1999, pp 1250-1256.

[4]. Aggarwal R., Xuan Q.Y., Dunn R.W., and Johns A.T., "A novel approach to fault diagnosis in multicircuit transmission lines using fuzzy ARTmap neural networks", *IEEE Trans. PWRD*, Vol. 10, September 1999, pp 1214-1221.

[5]. Al-hassawi W., Abbasi N., and Mansour M., "A neural-network-based approach for fault classification and faulted phase selection", *Canadian Conference on Electrical and Computer Engineering, CCECE'96*, IEEE 1996, pp 384-387.

[6]. Al-Dabbagh M., and Al-Dabbagh L., "Neural networks algorithm for detecting high impedance faults on power distribution lines", *International Joint Conference on Neural Networks, 1999, IJCNN'99*, IEEE, pp 3386-3391.

[7]. Alessandro F., Sangiovanni S., and Zappitelli E., "A fuzzy sets approach to fault type identification in digital relaying", *IEEE Trans. PWRD*, Vol. 10, n° 1, Jan 1995, pp 169-175.

[8]. Altuve H. J., e.t. al, "A neural network approach to fault detection in electric power systems", *Second World Automatic Congress*, Montpellier, France, May 1996

[9]. Altuve H., Vázquez E., Chacón O., Posadas D., y Sánchez E., "Aplicacion de redes de neuronas artificiales en protección de lineas de transmisión", *III Simposio Iberoamericano sobre Protección de Sistemas Eléctricos de Potencia*, Monterrey, N.L. México 1996.

[10]. Anderson P. M., *Power System Protection*, IEEE Press, 1999.

[11]. Bachmman B., Novosel D., Hart D., Hu Y., and Mohan M., "Application of artificial neural networks for series compensated line protection", *IEEE Trans PWRD-96* Vol 1, pp 68-73.

[12]. Bastard P., et al. "Neural network based algorithm for power transformer differential relays" *IEE Proc.* C, Vol. 142 n° 4 1995 pp 386-392.

[13]. Benmouyal G., and Roberts J., "Superimposed quantities: their true nature and application in relays", *26th Annual Western Protective Relay Conference*, Spokane, WA, U.S.A., October 1999.

[14]. Benmouyal G., and Mahseredjian J., "A combined directional and faulted phase selector element based on incremental quantities", *IEEE Trans. PWRD*, Vol. 16, No 4, October 2001.

[15]. Bewley L. V., *Travelling Waves on Transmission Systems*, New York, John Wiley and Sons. 1933.

[16]. Bin Su, Xinzhou D., Yuanzhang Sun, and Bo Z., "New principle of high-speed directional relay", *IEEE Proc. Power Engineering Society, Summer Meeting 2002*

[17]. Bo Z. Q., Li H. Y., Aggarwal R.K., Johns A., and Moore P. C., "Non-communication protection of transmission line based on genetic evolved neural network", *6th Int. Conf. on Developments in Power System Protection*, IEE, pp 291-294.

[18]. Bo Z. Q., e.t. al. "A new approach to phase selection using fault generated high frequency noise and neural networks", *IEEE PES Winter Meeting*, WM 024-0-PWRD, Baltimore, January 1996.

[19]. Bo Z. Q., Aggarwal R., and Jonhs A.T., "A novel technique to distinguish between transient and permanent faults based on the detection of current transients", *Proc. of 4th International Conference on Advances in Power System Control, Operation and Management*, APSCOM-97, Hong Kong, November 1997.

[20]. Boheme K., and Kulicke B., "Optimierung von distanzschutz algorithmen mit hilfe nueronnaler netze", *ELEKTRIE*, January 1993, Berlin, Germany.

[21]. Burges C.J., A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery*, to appear.

[22]. Burkit A. N., "Optimization of the architecture of feed forward neural networks with hidden layers by unit elimination", *Complex Syst.*, Vol. 5, 371-380.

[23]. Burrus C., Gopinath R., and Guo H., *Introduction to Wavelets and Wavelets Transforms*, Prentice Hall, 1998.

[24]. Cho K. R., Kang Y.C., Kim S.S., and Kim K.H., " An ANN approach to improve the speed of a differential equation based distance relaying algorithm", *IEEE Trans. PWRD-99*, Vol. 14, N° 2, April, pp 349-357.

[25]. Chul-Hwan K., Hyun K., Young-Hun, Sung-Hyun, Aggarwal R., and Johns A.,"A novel fault-detection technique of high-impedance arcing faults in transmission lines using the wavelet transform", *IEEE Trans. Power Delivery*, Vol. 17, No 4, October 2002.

[26]. Cichoqui A., and Lobos, "Artificial neural networks for real time estimation of basic waveforms of voltages and currents", *IEEE Trans. on Power Systems*, 1994, pp 612-618.

[27]. Conde A., *Protección Adaptiva de Sobrecorriente*, Tesis de Maestría en Ciencias. FIME-UANL, Monterrey, N.L. México, Febrero de 1996.

[28]. Coury D. V., Jorge D.C., "Artificial neural network approach to distance protection of transmission lines", *IEEE Trans. PWRD*, Vol. 13, n° 1, January 1998, pp 102-108.

[29]. Curso Tutorial sobre protección de líneas de transmisión, *V simposio Iberoamericano sobre protección de sistemas eléctricos de potencia*, Monterrey, México, Nov. 2000.

[30]. Dalstein T., Dejan J., Kulicke B., and Yoh-Han P., "Neural network approach to fault direction identification in electric power systems", *North American Power Symposium*. October 1993.

[31]. Dalstein T., and Bern K., "Neural network approach to fault classification for high speed protective relaying", *94 SM 488-7 PWRD*.

[32]. Dalstein T., e.t. al., "Neural network approach to fault type discrimination for high speed protective relaying", *IEEE Trans. PWRD*, Vol. 10, nº 2, April 1995

[33]. Dalstein T., T. Friedrich, B. Kulicke, and D. Sobajic, "Multi neural network based fault area estimation for high speed protective relaying", *IEEE Trans. PWRD*, Vol. 11, nº 2, April 1996, pp 740-747.

[34]. Deri A, Tevan, Semlyem A., and Castaneira A., "The complex ground return plane: a simplified model for homogeneous and multi-layer earth return", *IEEE Trans. PWRD*, 1981.

[35]. Díaz L., *Estudio Comparativo de Algoritmos de Filtrado Digital para Protección de Líneas de Transmisión*. Tesis de Maestría en Ciencias, FIME-UANL, Monterrey, N.L., México. Diciembre de 1994.

[36]. Dommel H.W., and Michels J.M., "High speed relaying using travelling wave transient analysis", *IEEE PES Winter Power Meeting*, New York, January 1978, Paper No. A78 - 214-9.

[37]. Dommel H.W., *Electromagnetic Transients Program, Reference Manual*, (EMTP- Theory Book), Prepared for Bonneville Power Administration, PO. Box 3621, Portland, Ore. 1986.

[38]. Dommel H.W., "Digital computer solution of electromagnetic transient in single and multiphase networks", *IEEE Trans. on Power Apparatus and Systems*, pp 388-398

[39]. Dubanton C., "Cálculo aproximado de los parámetros primarios y secundarios de una linea de transmision: valores homopolares", *EDF Bulletin de la Direction des Estudess et Recherches*, n 1, 1969.

[40]. Ebron S., Lubkeman D., and Mark W., "A neural network approach to the detection of incipient faults on power distribution feeders", *IEEE Trans. on Power Delivery*, Vol. 5, nº2, April 1998, pp 905-912.

[41]. El-Sharkawi M. and Neibur D., *Artificial Neural Networks with Applications to Power Systems*, IEEE tutorial Course Text, Publication nº 96, TP 112-0, 1996.

[42]. Fitton D.S., e.t. al. "Desing and implementation of an adaptive single pole autoreclosure technique for transmission lines using artificial neural networks", *IEEE Trans. on Power Delivery*, Vol. 11, nº 2, April 1996.

[43]. Fitton D.S., Dunn R.W., Aggarwal R.K., Johns A.T. and Song Y S., "The application of neural networks techniques to adaptive autoreclosure in protection equipment", *5th Int. Conf. on Developments in Power System Protection*, pp.161-164.

[44]. Galloway R. Shonocks B., and Wedepohl L. M., "Calculation of electrical parameter for short and long polyphase transmission lines", *Proc. IEE*, 1964.

[45]. Gao J., and Ding X., "On improvement of feature extraction algorithms for discriminative pattern classification", *15th International Conference on Pattern Recognition*, IEEE, June 2000.

[46]. Gary C., "Análisis de la propagación de ondas a través de conductores múltiples en alta frecuencia utilizando matrices complejas", *Proc. IEE*, 1976.

[47]. Gutiérrez M., Wang J., and Grondin R., "Estimating hidden unit number for two layer perceptron", *Proc. IEEE/INNs, Int. Joint Conf. on Neural Networks*, Washington, DC., Vol. 1, 677-681.

[48]. Gustavsen B., and Semlyem A., "Simulation of transmission line using vector fitting and modal decomposition", 1997 *IEEE Winter Meeting*, New York, paper PE-347 PWRD-0-01-97.

[49]. Haykin S., *Neural Networks: a Comprehensive Foundation*, Prentice Hall, 2nd ed., 1999.

[50]. Horowitz S.H., et. al, "Adaptive transmission system relaying", *IEEE Transactions on Power Delivery*, Vol. 3, nº 4, October 1988.

[51]. Huisheng W., and Keerthipala W.W., "Fuzzy-neuro approach to fault classification for transmission line protection", *IEEE Trans. PWRD*, Vol. 13, October 1998, pp. 1093-1104.

[52]. IEEE Committee Report, "Optical current transducers for power systems: A review", IEEE Paper 94 WM 241-0 PWRD, *IEEE PES Winter Meeting*, New York, Jan 30 - Feb 3, 1994.

[53]. Jongepier A.G., and Van Der Luis L., "Adaptive distance protection of double – circuit lines using artificial neural networks", *IEEE PES Winter Meeting*, Paper nº 96, WM 023-0-PWRD, Baltimore, January 1996.

[54]. Jordan E., and Keith B. G., *Electromagnetic Waves and Radiating Systems*, Prentice Hall, 2nd Edition, 1968, Englewood Cliffs, N. J

[55]. Keerthipala W.W. L., Chan T. W., Kee C. S., Hu L. P., and Wang H., "Neural network based software relay for power system protection", *Proc. of the International Conference on Advances in Power Systems, Control & Management* (APSCOM-95), Hong Kong, Nov 1995, pp 340-345.

[56]. Kezunovic M., e.t. al, "High speed fault detection and classification with neural nets", *Electric Power Systems Research*, Vol. 34, pp 109-116, 1995.

[57]. Kezunovic M., e.t. al, "Real – time and off –line transmission line fault classification using neural network", *Engineering Intelligent Systems*, Vol. 34, pp 57-63, 1996.

[58]. Kezunovic M. e.t. al, "Neural Network applications to real time and off-line fault analysis", *Intl. Conf. on Intelligent Systems Applications to Power Systems*, 1994.

[59]. Khaparde S.A., et. al, "Application of artificial network in protective relaying of transmission lines", *Proc. first ANNPS'91*, Seattle, Washington, July 1991.

[60]. Lippmann R.P., "An introduction to computing with neural nets", *IEEE ASSP Magazine*, April 1987.

[61]. Looney C., *Pattern Recognition Using Neural Networks; Theory and Algorithms for Engineers and Scientists*". Oxford University Press. 1997.

[62]. Lubkeman D., et. al., "Unsupervised learning strategies for the detection and classification of transient phenomena on electric power distribution system". *Proceedings of the First ANNPS'91*, Seattle, Washington, July 1991.

[63]. Mechanouri A., and Thomas D., "A new principle for high resistance earth fault detection during fast power swings for distance protection". *IEEE Trans. PWRD*. Vol. 12, N° 4, October 1997, pp 1452-1457.

[64]. Minkner R., and Schweitzer E. O., "Low power voltage and current transducers for protecting and measuring medium and high voltage systems". *26th Annual Western Protective Relay Conference*, Spokane, WA, U.S.A., October 1999.

[65]. Mohamed E., and Rao N, "Artificial neural networks based fault diagnostic system for electric power distribution feeders", *Electric Power Systems Research*, Vol 35, n° 1, Oct 1995, pp 1-10.

[66]. Moreno P., De la Rosa R., and Naredo J. L., "Frequency Domain computation of transmission line closing transients", *IEEE Trans. PWRD* 1981, Vol. 6, n° 1.

[67]. Naredo J.L., Moreno P., Guardado L., y Gutiérrez A., "La transformada numérica de Laplace como una herramienta de investigación y desarrollo en ingeniería eléctrica". *CIIE-98*, Aguascalientes, México, 1998.

[68]. Naredo J.L., *Introducción a los Transitorios Electromagnéticos*. CINVESTAV -IPN, Unidad Guadalajara, México, Enero 2000.

[69]. Novosel D., e.t. al. "Algorithms for locating fault on series compensated lines using neural networks and deterministic methods", *IEEE PES Winter Meeting*, Paper n° 96 WM 021-0-PWRD, Baltimore , January 1996.

[70]. Oleskoviez M., Coury D., and Aggarwal, "A complete scheme for fault detection, classification and location in transmission lines using neural networks", *Developments in Power System Protection*, Conference Publication No. 479, IEE 2001, pp 335-338.

[71]. Oppenheim A.V., and R.W. Schafer, *Digital Signal Processing*, New Jersey, Prentice-Hall, Inc., Englewood Ciffs, 1975.

[72]. Ortiz V.H., Altuve H.J., Vázquez E., y Chacón O., "Aplicación de la transformada wavelet en el desarrollo de una protección neuronal para líneas". *Proc. VII Jornadas Hispano-Lusas*, Madrid, España 2001.

[73]. Ortiz V.H., Altuve H.J, y Vázquez E, "Inclusión de un extractor de rasgos distintivos en un estimador neuronal de zona de falla", *Memoria Técnica de la Reunión de Verano de Potencia y Aplicaciones Industriales RVPAI-2001*, Acapulco, Méx., 2001.

[74]. Ortiz V.H., Altuve H.J, Vázquez E, "Caracterización de señales de fallas monofásicas en líneas de transmisión", *Memoria Técnica de la Reunión de Verano de Potencia y Aplicaciones Industriales RVPAI-2001*, Acapulco, Méx., 2001.

[75]. Ortiz V.H., Altuve H.J, Vázquez E. Chacón O.L., "Evaluación de estimadores de zona de falla para líneas de transmisión basados en redes de neuronas artificiales y onduletas"

Memoria de la Conferencia Internacional en Ingeniería Eléctrica y Electrónica, Santiago de Cuba, Cuba, 2002.

[76]. Ortiz V.H., Uribe F.A., Gutiérrez J.A., and Altuve H.J., "Arcing fault patterns for ANN based relay for transmission lines", *Proc. POWERTECH 2003*, Bologna, Italia, July 2003.

[77]. Ortiz V.H., y Gutiérrez J. A., "Efecto de los limitadores de corrientes de falla sobre los elementos de protección de distancia", *Memoria Técnica CIECE'04*, Guadalajara, Mex., 2004.

[78]. Phadke A. G., and James S. Thorp, *Computer Relaying for Power Systems*, Research Studies Press LTD, 1988.

[79]. Pinto de Sá Afonso J., and Rodriguez J.R., "A probabilistic approach to setting distance relays in transmission networks", *IEEE Trans. PWRD-1997*, Vol. 12, Nº 2 pp. 681-686.

[80]. Pollaczec F., "On the field produced by an infinite long wire carrying alternating current", *Electrisch Nachrichden Tentechnik*, Vol. 3, pp. 339-359, 1926.

[81]. Posadas D., "*Aplicación de Neuronas Artificiales a la Protección de Distancia*", Tesis Maestria, FIME-UANL, Monterrey, N.L., México, 1998.

[82]. Qi W., G. Swift, P. McLaren, and A. Castro, "Distance protection using an artificial neural Network", *6th Int. Conf. On Developments in Power System Protection*, IEE Pub no 436.

[83]. Quianli S., Xinzhou D. and Bo Z., "New Approach of Fault Detection and Fault Phase Selection Based on Initial Current Traveling Waves", *Proc. Power Engineering society Summer Meeting*, 2002, IEEE, pp 393-398.

[84]. Ramirez A., *Modelado de Sistemas de Transmisión de Energia en el Dominio del Tiempo Incluyendo Efectos de Dispersión Lineal y No-lineal*", Tesis de Maestria, UdeG, Guadalajara, Jal., México 1998.

[85]. Sachdev M.S., *Microprocessor relays and protection system*", IEEE tutorial Course Text, Publication nº 88EHO269-1PWR, February 1998.

[86]. Schweitzer E.O., and Daqing Hou, "Filtering for protective relays," *19th Annual Western Protective Relay Conference*, Spokane, Washington, October 1992.

[87]. Schweitzer E.O, "*Tópicos selectos de protección digital de sistemas eléctricos de potencia*," 5º Curso Avanzado de Protección de SEP, UANL, Texto Editado por Schweitzer Engineering Laboratories, Inc, Pullman, WA, USA, Octubre 1999.

[88]. Sidhu T.S., et, al, "Design, implementation and testing of artificial neural network based fault direction discriminator for protecting transmission lines", *IEEE Trans PWRD*, Vol. 10, nº 2, April 1995, pp 697-706.

[89]. Sidhu T.S., Singh H., and Sachdev M.S, "An artificial neural network for directional comparison relaying of transmission lines", *6th Int. Conf. On Developments in Power System Protection*, IEE Pub no 433.

[90]. Sobajic, D.J. Pao, and Y.H. Dolce, "On line monitoring of power systems operating conditions using artificial neural networks", *IEEE International Symposium on Circuit and Systems*, Portland, OR, May 1989, pp 2243-2246.

[91]. Song Y. H., "Genetic algorithm based neural networks applied to fault classification for HHV transmission lines with a UPFC", 6th *Int. Conf. on Developments in Power System Protection*, IEE Pub n° 434.

[92]. Song Y., Xuan Q., Jonhs A., and Aggarwal R., "Integrated adaptive protection and control for controllable series compensated transmission system using neural networks", *AC and DC Power Transmission*, 29 April- 3 May 1996, Conference Publication No 423, IEE, 1996, pp. 334-339.

[93]. Takagi T., Baba J., Uemura K., and Sakaguchi T., "Fault protection based on travelling wave theory Part I: Theory", *IEEE Summer Meeting*, Mexico City, Paper No A77- 750-3.

[94]. The Math Works Inc. *User's Guide*, 1998.

[95]. Uribe F. A., *Técnicas del Dominio de la Frecuencia Aplicados al Análisis de Transitorios Electromagnéticos en Cables de Transmisión de Energía Eléctrica*", Tesis de Maestria, UdeG, Guadalajara, Jal., México, 1998.

[96]. Wedepohl L.M., "Application of matrix methods to solution of travelling wave phenomena in polyphase systems", *Proc. IEE* ,Vol. 110, pp 2200-2212.

[97]. Wedepohl L.M., "Power system transients: errors incurred in numerical inversion of Laplace transform", *Proc. MEXICON*, Puebla, Méx. 1983.

[98]. Weigend A., Rumelhart D., and Huberman B., "Generalization by weight-elimination applied to currency exchange rate prediction", *Proc. Conf. Neural Networks*, Seattle, Vol. 1, 837-841.

[99]. Websper S., Dunn R., Aggarwal R., Johns A., and Bennet A., "Feature extraction methods for neural network-based transmission line fault discrimination", *Generation, Transmission and Distribution, Proc. IEE*, Vol. 146, No. 3, May 1999, pp 232-238.

[100]. Widrow B., Lehr, "30 year of adaptive neural networks: perceptron, madeline and backpropagation", *Proceeding of the IEEE*, Vol. 78, n° 9, September 1990.

[101]. Wilson E., and Tufts D., "Multilayer perceptron design algorithm", *IV Proc. of the Neural Networks for Signal Processing*, IEEE Workshop, May 1994.

[102]. Working Group of Study Committee 33, CIGRE, *Guidelines for Representation of Network Elements When Calculating Transients*, Paris, 1991.

[103]. Yasmine Assef, Bastard P., and Meunier M., "Artificial neural networks for single phase fault detection in resonant grounded power distribution systems", *Proc. IEEE Transmission and Distribution Conference*, 1996, pp 566-571.

[104]. Zhang Z., McLaren P., Swift G., Dirk E. and Fernando I., "An accurate software model for on-line assessment of digital relay", CCECE Conference, Calgary, May 26-29, 1996

[105]. Zhihong Chen, and Jean-Claude Maun, "An artificial neural network based real-time fault locator for transmission lines", *Trans. PWRD*, January 1997, pp. 163-168.

APÉNDICE A

MODELADO DE LA LÍNEA DE TRANSMISION AÉREA MONOFÁSICA

En este apéndice se hace la deducción del modelo de una línea monofásica, incluyendo las pérdidas. Para iniciar el análisis se toman en cuenta los siguientes aspectos [68]

1. La propagación de las ondas electromagnéticas es sólo en forma transversal (TEM). En otras palabras, se supone que por la línea se transmiten ondas planas que viajan sólo a lo largo del eje z (ver Fig. A.1a).
2. No existe penetración de carga al interior del conductor, es decir, no habrá resistividad (ρ =0) y, a pesar de la proximidad, no hay penetración de campos electromagnéticos.
3. Los conductores son homogéneos a lo largo de la longitud de la línea.
4. El campo magnético B se propaga en forma excéntrica con respecto al centro del conductor (eje z) y es constante en todos los radios equidistantes.

Considérese una línea como la que se muestra la en Fig. A.1b, formada por un conductor cilíndrico de radio R, colocado horizontal con respecto al plano de tierra. Se supone que tanto el conductor como el plano de tierra son conductores perfectos, y que el plano de tierra es otro conductor colocado a una distancia D.

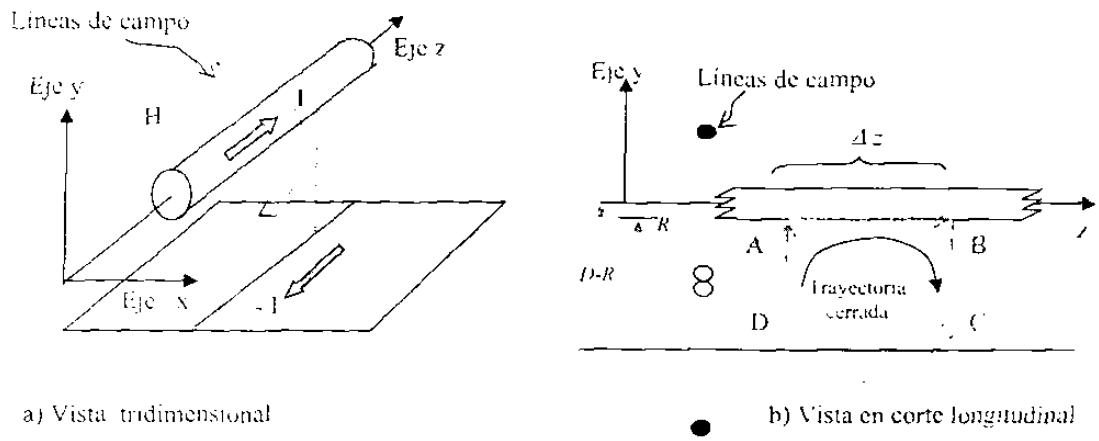

a) Vista tridimensional

b) Vista en corte longitudinal

Fig. A.1 Línea monofásica ideal.

Para obtener la Primera Ecuación del Telegrafista se aplica la Ley de Faraday:

$$\oint_{ABCD} \overline{E} \bullet d\overline{l} = -\frac{\partial}{\partial t} \int \overline{B} \bullet d\overline{a} \qquad (A.1)$$

La expresión del lado izquierdo de (A.1) denota una integral cerrada para la trayectoria ABCD, siendo E el campo eléctrico, dl una diferencial de longitud y da una diferencial de área. La integral se soluciona para cada una de las trayectorias indicadas:

$$\oint_{ABCD} \overline{E} \circ d\overline{l} = \int_{z1}^{z2} E_z(0, R, z)dz$$

$$+ \int_{R}^{D-R} E_y(0, R, z)dy$$

$$- \int_{z1}^{z2} E_z(0, D-R, z)dz$$

$$- \int_{D-R}^{R} E_y(0, y, z)dy$$

Dado que se considera que no existe campo eléctrico tangencial a la superficie del conductor, entonces la primera y tercera integrales son cero. Las integrales restantes sobre la superficie del conductor representan caídas de voltaje, por lo cual la expresión del lado izquierdo de (A.1) se reduce a:

$$\oint_{ABCD} \overline{E} \bullet d\overline{l} = V_2 - V \tag{A.2}$$

Para resolver la parte del lado derecho de (A.1), se recurre a sustituir los elementos diferenciales de área, por diferenciales de superficie: $d\overline{a} = dydz\ \hat{x}$. De esta manera, la integral de superficie se cambia por una doble integral:

$$\int \overline{B} \bullet d\overline{a} = \iint B_x dydz \tag{A.3}$$

La densidad de campo magnético B es proporcional al campo magnético H, por lo que dichas componentes se pueden expresar en la forma:

$$H_x = \frac{I\hat{x}}{2\pi y} \qquad \text{y} \qquad H_y = \frac{I\hat{x}}{2\pi y} \tag{A.4}$$

En una sección diferencial de conductor Δz, la corriente se mantiene constante; por ello, se considera que B_x no es función de las componentes en el eje z. Esto permite sacar un término de la integral, quedando la trayectoria de integración A-D:

$$-\frac{\partial}{\partial t}\int \overline{B} \bullet d\overline{a} = \frac{\Delta x \mu}{2\pi}\left(\frac{\partial I}{\partial t}\right)\int_R^R \left(\frac{1}{y} + \frac{1}{D-y}\right) dy \tag{A.5}$$

En la Fig. A.1b se puede ver que los campos magnéticos en el espacio exterior se anulan por ser contrarios en signo, provocando que el segundo término dentro de la integral se elimine. En cambio, los campos magnéticos que se concentran en el espacio entre los dos conductores son del mismo signo. Esa simetría permite agregar directamente la contribución que proviene de la corriente de retorno tan sólo duplicando el resultado de (A.5), para llegar a:

$$-\frac{\partial}{\partial t}\int \overline{B} \bullet d\overline{a} = -\frac{\partial \phi}{\partial t} = -\mu \frac{\Delta z}{\pi}\left[\ln\left(\frac{D-R}{R}\right)\right]\frac{\partial I}{\partial t} \tag{A.6}$$

Igualando (A.6) con (A.2), dividiendo entre Δz y aplicando límite para $x \to 0$, se llega a la Primera Ecuación del Telegrafista:

$$-\frac{\partial v}{\partial z} = L\frac{\partial I}{\partial t} \tag{A.7}$$

La inductancia geométrica en este modelo monofásico sin pérdidas es:

$$L = -\mu \frac{\Delta z}{\pi}\left[\ln\left(\frac{D-R}{R}\right)\right] \approx -\mu \frac{\Delta z}{\pi}\ln\left(\frac{D}{R}\right) \qquad (A.8)$$

La ecuación (A.8) hace evidente que para cada disposición geométrica habrá una inductancia L, que es función de la distancia física entre el conductor y el plano de tierra, así como del radio del conductor R y otros factores. En la práctica, la complejidad del problema de modelar esta inductancia es todavía mayor, debido a que todas las líneas mantienen una disposición geométrica no uniforme, en la cual varía la altura de catenaria, la resistividad de tierra a lo largo de la longitud de la línea, y otros factores [37].

Para obtener la Segunda Ecuación del Telegrafista, se aplica la Ley de Ampere a la trayectoria cerrada mostrada en la Fig. A.2ᵃ:

$$\oint_{ABCD} \overline{H} \bullet dl = \int (\overline{J} + \overline{D}) \bullet d\overline{a} \qquad (A.9)$$

siendo la densidad de corriente $\overline{J}$ y $\overline{D}$ es el vector de desplazamiento de carga sobre el conductor. La parte izquierda de (A.9) es la integral descrita en la trayectoria cerrada de la Fig. A.2b, y se resuelve en forma separada para cada trayectoria:

$$\oint_{ABCD} \overline{H} \bullet dl = \int_{A \to B} + \int_{B \to C} H 2\pi r + \int_{C \to D} + \int_{D \to A} H 2\pi r \qquad (A.10)$$

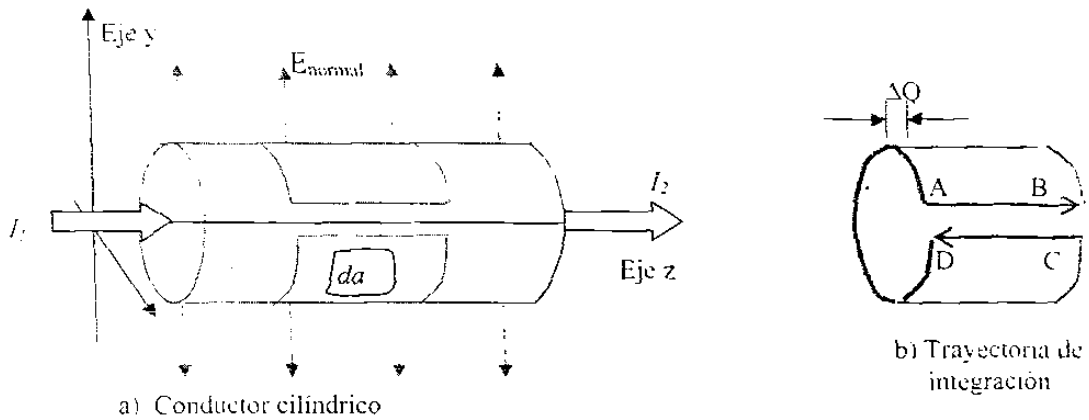

Fig. A.2 Circulación de corrientes en una línea ideal.

En la Fig. A.2b puede verse que las trayectorias $A \rightarrow B$ y $C \rightarrow D$ coinciden, pero producen campos magnéticos con sentidos opuestos; por ello, sus términos correspondientes en (A.10) se anulan. De las dos integrales restantes se obtiene:

$$\oint_{ABCD} \overline{H} \bullet dl = I_1 - I_2 \tag{A.11}$$

La parte del lado derecho de (A.9) se reduce a:

$$\int (\overline{J} + \overline{D}) \bullet d\overline{a} = \frac{\partial}{\partial t} \int \overline{B} \bullet d\overline{a} = \frac{\partial}{\partial t} \oint \overline{B} \bullet d\overline{a} \tag{A.12}$$

La ecuación (A.12) indica que el desplazamiento de cargas es igual a la carga encerrada, pudiéndose por tanto realizar una integral cerrada, al igual que una integral de superficie. En este caso con un conductor ideal, no existe carga interna y, por ello, la contribución de las caras por donde fluye la carga es cero (ver Fig. A.2b). La solución de (A.12) se obtiene expresando la carga en por unidad de longitud ΔQ. Igualando ese resultado con el de (A.11) se tiene:

$$I_1 - I_2 = \Delta z \; C \; \frac{\partial V}{\partial t} \tag{A.13}$$

Dividiendo (A.13) entre Δz y haciendo tender a cero la diferencia, se obtiene la Segunda Ecuación del Telegrafista:

$$-\frac{\partial I}{\partial z} = C \frac{\partial v}{\partial t} \tag{A.14}$$

En (A.14) se demuestra que se cumple con el principio de la conservación de la carga, es decir, que siempre existe un conductor por el cual retorna la corriente. En este caso se ha considerado que el plano de tierra es otro conductor ideal, y por éste regresa la corriente. En la solución de las Ecuaciones del Telegrafista se basan los métodos conocidos como de onda viajera en el programa EMTP [37].

En el modelo de línea de transmisión ideal se considera que se tiene una superficie equipotencial a lo largo de toda su longitud, con un potencial dado por la Primera Ecuación del Telegrafista. Las componentes de pérdidas no se obtienen directamente; éstos suelen incorporarse posteriormente. La capacitancia de la línea se calcula por

unidad de longitud, obteniéndose a partir de la inductancia geométrica (A.8), ya que se cumple:

$$CL = \mu\varepsilon \tag{A.15}$$

donde ε es la constante dieléctrica del aire y μ es la permeabilidad del vacío. La velocidad u con que se propaga la onda por una línea ideal es igual a:

$$u = \frac{1}{\sqrt{CL}} = \frac{1}{\sqrt{\mu\varepsilon}} = 3 \cdot e^{8} \ m/s \tag{A.16}$$

Para incluir las pérdidas en el modelo de línea ideal se requiere hacer un análisis detallado de la distribución de los campos en el conductor e involucrar en este estudio otros parámetros geométricos del sistema de transmisión. De esa manera se determinan la impedancia serie y la admitancia paralelo de la línea [**46**].

Para calcular la impedancia serie de la línea aérea a una frecuencia específica, se supone que la radiación electromagnética es principalmente exterior al conductor, existiendo componentes de campo normales y tangenciales, tal como se muestra en la Fig. A.3. Se observa que la corriente no se reparte uniformemente a través del área transversal del conductor, y que el centro de cargas se desplaza con respecto al centro del conductor en función de la resistividad y del tiempo en que se establecen los reacomodos de cargas [**54**].

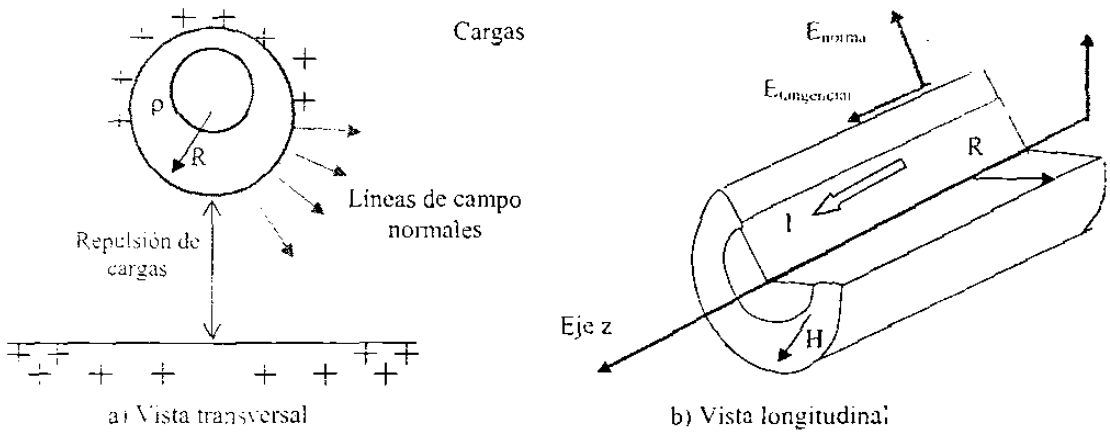

Fig. A.3 Geometría de superficies equipotenciales con centros fuera del origen.

Ese fenómeno de desplazamiento de cargas a escala molecular resulta muy complicado de modelar [**39**,**44**]. La manera en que se suelen incluir EN la impedancia de la línea Z_l esas componentes que representan pérdidas, implica agregar otras componentes de impedancia al modelo de línea ideal presentado anteriormente:

$$Z_L = Z_g + Z_{cond} + Z_t \tag{A.17}$$

Las componentes adicionales a la impedancia geométrica, que representan las pérdidas, son la impedancia del conductor Z_{cond} y la impedancia de retorno por tierra Z_t. La práctica más común para calcular la impedancia del conductor Z_{cond}, se basa en la solución de una expresión que es función de la frecuencia angular ω y la densidad de corriente, y que obedece a la siguiente ecuación diferencial [**54**]:

$$\frac{d^2}{dR^2} J_z(R) + \frac{1}{R}\frac{d}{dR} J_z(R) - \gamma^2 J_z(R) = 0 \tag{A.18}$$

donde γ es la constante de propagación, y p es la profundidad compleja de penetración por efecto piel, que se relaciona con γ de la siguiente forma:

$$\gamma^2 = \frac{j\omega\mu}{\rho} = \frac{1}{p^2} \tag{A.19}$$

La ecuación (A.19) describe el efecto piel o efecto pelicular, y corresponde a la ecuación de *Bessel* de orden cero, cuya solución general es la siguiente:

$$J_z(R) = A\ I_0(\gamma\ R) + B\ K_0(\gamma\ R) \tag{A.20}$$

donde A y B son constantes arbitrarias, e I_0 y K_0 son las funciones modificadas de Bessel de orden cero, de primera y segunda especie, respectivamente [46]. Para los casos más comunes de líneas aéreas, que es cuando el núcleo del conductor se puede considerar un cilindro sólido, se tiene una expresión más simple para calcular la impedancia por unidad de longitud [**95**]:

$$Z_{cond} = \frac{E_{\tan gencial}}{I} = \frac{\rho\gamma}{2\pi R}\frac{I_0(\gamma\ R)}{I_1(\gamma\ R)} \tag{A.21}$$

Donde I es la corriente total obtenida integrando la ecuación.

Otra componente de impedancia serie que se incluye en la ecuación (A.17), y que representa pérdidas, es la impedancia de retorno por tierra Z_t. Esta impedancia provoca una caída de tensión longitudinal, que es inducida entre el conductor y el plano de tierra, básicamente porque éste no se comporta como un conductor perfecto; por tanto, los campos electromagnéticos penetran en el conductor (Fig. A.4).

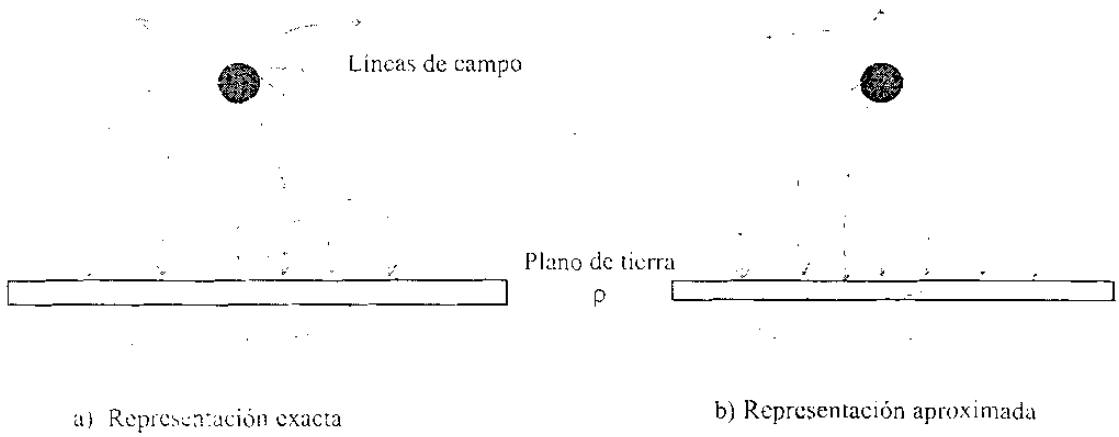

Fig. A.4 Penetración de carga en el plano de tierra.

Considerando que el suelo es homogéneo, o sea, que la resistividad es la misma para todos los puntos dentro de éste, los términos de corrección de impedancias propias y mutuas son, respectivamente:

$$Z_{tii} = \frac{\mu\omega}{\pi}\int_0^{\infty}\frac{je^{-2h_i\alpha}}{\alpha+\sqrt{\alpha^2+j\omega\sigma\mu}}d\alpha \qquad \text{(A.22)}$$

$$Z_{tij} = \frac{\mu\omega}{\pi}\int_0^{\infty}\frac{je^{-(h_i+h_j)\alpha}}{\alpha+\sqrt{\alpha^2+j\omega\sigma\mu}}\cos(\alpha\ D_{ij})d\alpha \qquad \text{(A.23)}$$

Estas últimas expresiones son las integrales de Carson, para las cuales no se ha reportado solución analítica. Sin embargo, se han desarrollado expresiones que dan su valor en forma aproximada [34]. Por ejemplo, al considerar que dentro del suelo los campos eléctricos y magnéticos son planos y paralelos a la superficie (ver Fig.A.5b), los campos vectoriales E, H y J deben obedecer a la ecuación del efecto piel para un conductor plano:

$$\frac{d^2}{dz}\begin{Bmatrix} E_z \\ H_x \\ J_z \end{Bmatrix} = j\omega\mu\sigma\begin{Bmatrix} E_z \\ H_x \\ J_z \end{Bmatrix} \tag{A.24}$$

Por tanto:

$$E_z(y) = E_0 e^{\gamma y} \tag{A.25a}$$

$$H_x(y) = H_0 e^{\gamma y} \tag{A.25b}$$

$$J_z(y) = J_0 e^{\gamma y} \tag{A.25c}$$

Donde E_z, H y J_z son los valores en la superficie. Por ejemplo, en la Fig. A.5 se muestra el comportamiento de la solución de (A.25b), con una acumulación del campo en forma exponencial decreciente en el sentido negativo del eje y. Para la línea mostrada en la Fig. A.5a, el flujo magnético entre el conductor y el suelo sirve para obtener el valor de la inductancia geométrica de la línea. El flujo magnético bajo el piso, para una franja de ancho Δz, se obtiene integrando la expresión (A.25b).

Este último resultado indica que el flujo magnético dentro de la tierra equivale al del rectángulo de la Fig. A.25b, dentro del cual el campo H se ha considerado constante e igual a H_0. Integrando (47b), resulta que la profundidad del rectángulo de la Fig A.5b es:

$$p = \frac{1}{\gamma} = \frac{1}{\sqrt{j\omega\varphi\sigma}} \tag{A.26}$$

En el cálculo de inductancias geométricas y de tierra de la línea monofásica se utiliza el método de las imágenes, colocando el plano de reflexión a una profundidad compleja p. Se llega a obtener la siguiente expresión:

$$L = \frac{\mu}{2\pi}\int_R^{D+p}\frac{dz}{z} = \frac{\mu}{2\pi}\ln\left(\frac{D+p}{R}\right) \tag{A.27}$$

La ecuación (A.27) se puede descomponer en:

— — —

APÉNDICE B

ESPACIO DE SEÑALES Y TEORÍA DE ONDULETAS

Un vector X en el espacio n-dimensional se caracteriza por sus componentes $(x_1, x_2, x_3, \ldots x_n)$

$$X = \sum_{k=1}^{n} x_k i_k \tag{B.1}$$

donde i_k, $1 \leq k \leq n$, es el conjunto de vectores unitarios del sistema de coordenadas de referencia. Se define el producto interno entre dos vectores n-dimensionales reales $X = x_1, x_2, x_3, \ldots x_n$ y $Y = y_1, y_2, y_3, \ldots y_n$ como:

$$X \cdot Y = \sum_{k=1}^{n} x_k y_k \tag{B.2}$$

y la magnitud o norma de un vector X como:

$$\|X\| = (X \cdot X)^{1/2} = \left[\sum_{k=1}^{n} x_k^2 \right]^{1/2} \tag{B.3}$$

Cuando un producto interno es igual a cero, se dice que los vectores son ortogonales; esta relación equivale al teorema de Pitágoras en un espacio de n dimensiones.

$$\|X + Y\|^2 = \|X\|^2 + \|Y\|^2 \tag{B.4}$$

La proyección de un vector X en otro vector Y está dada por:

$$proy_Y X = \frac{X \cdot Y}{\|Y\|} \tag{B.5}$$

y el vector proyectado es:

$$X_Y = \frac{X \cdot Y}{\|Y\|} \frac{Y}{\|Y\|} = \frac{X \cdot Y}{Y \cdot Y} Y \tag{B.6}$$

Fig. B.1 Proyección de vectores.

En la Fig. B.1 se observa que, de todos los vectores cY, en la dirección de Y, el más "cercano" a X es precisamente el vector proyectando X_Y; se define un vector de "error" entre X y cY como:

$$e = X - cY \tag{B.7}$$

El vector X_Y minimiza la magnitud o la norma del vector error $\|e\|$; en esta situación, el vector de error e es perpendicular a Y (y por ende también a X_Y), y se cumple:

$$e \cdot Y = (X - X_Y) \cdot Y = X \cdot Y - \frac{X \cdot Y}{Y \cdot Y} Y \cdot Y = 0 \tag{B.8}$$

Así, dos vectores X y Y son perpendiculares u ortogonales si su producto interno es cero. Un conjunto de vectores $\{\Phi_k\}$, $1 \leq k \leq n$ es ortogonal si:

$$\phi_k \cdot \phi_m = 0 \ \forall \ k \neq i \tag{B.9}$$

Un conjunto de vectores es ortonormal, si es ortogonal y cada vector tiene norma unitaria. Se dice que los vectores son linealmente independientes cuando ninguno de ellos puede representarse como una combinación lineal de los otros restantes. Un conjunto de vectores que son ortogonales, son también linealmente independientes, pero los vectores pueden ser linealmente independientes sin ser ortogonales.

Si $\{\Phi_k\}$, $1 \leq k \leq n$ es un conjunto ortogonal de vectores, un vector X en el espacio n-dimensional puede representarse como una combinación lineal de los vectores $\{\Phi_k\}$.

Las onduletas son una base de funciones definidas en tiempo continuo, con las cuales se puede generar todo un conjunto de vectores [**23**]:

$$f(t) = \text{ combinación de funciones base } = \sum_{j,k} b_{jk} \Phi_{jk}(t) \qquad \text{(B.10)}$$

En esta base, las funciones $\Phi_{jk}(t)$ se construyen a partir de una onduleta madre. Se presupone que la onduleta madre es finita en tiempo y que está contenida en una ventana normalizada de 0 a 1 (con las N muestras que forman un período de observación). Todas las onduletas que se derivan de la onduleta madre tienen la propiedad de ser ortogonales entre sí y de empezar en un tiempo t=0 y terminar en $t=N/2j$, de manera que sus gráficas terminan comprimidas por el factor $2j$, y a su vez trasladadas en tiempo k veces.

La condición preestablecida de usar una base ortogonal se aprovecha para deducir una fórmula simple para calcular los coeficientes b_{jk} de la expansión $f(t)$, en la forma:

$$\int_{-\infty}^{\infty} f(t)\Phi_{jk}(t)dt = b_{jk} \int_{-\infty}^{\infty} (\Phi_{jk}(t))^2 dt \qquad \text{(B.11)}$$

Todos los otros términos desaparecen, debido a las propiedades de ortogonalidad. Con esta representación vectorial es posible analizar señales no estacionarias en tiempo y frecuencia, lo que implica un análisis simultáneo en los dominios del tiempo y de la frecuencia. Además, es posible detectar el instante en que ocurre una perturbación, su duración, el espectro según el nivel de frecuencia presente, y otras características del evento. La información resultante del análisis puede ser de gran interés a efectos de proporcionar patrones fácilmente reconocibles de los distintos tipos de fallas.

Los conceptos anteriores se cumplen de igual forma para el caso discreto. La implementación de la Transformada Wavelet Discreta (DWT) se realiza usando el algoritmo de Análisis Multirresolución (MRA). Esto es, se descompone una señal digitalizada $f(n)$, que es una versión muestreada de la función $f(t)$, en escalas con diferente resolución tiempo-frecuencia (ver Fig. B.2). El objetivo del MRA es expresar una función arbitraria $f(t) \in L^2$ en varios niveles de detalles.

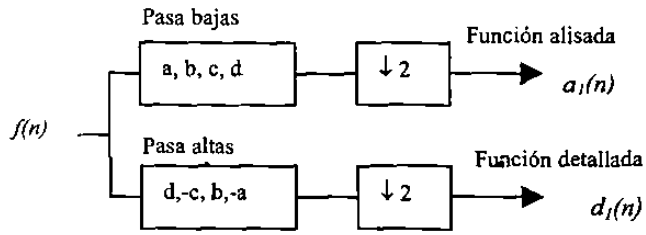

Fig. B.2. Filtro de cuatro coeficientes para implementar el algoritmo MRA.

La secuencia $f(n)$ se descompone mediante el MRA en la versión "aproximada" o "alisada" $a_1(n)$, (que contiene las componentes de baja frecuencia), y la versión detallada $d_1(n)$ (que contiene las componentes de alta frecuencia). Esta es la descomposición en la primera escala. La descomposición en la siguiente escala se hace para la señal $a_1(n)$, que se descompone a su vez en una versión menos fina $a_2(n)$ y sus detalles $d_2(n)$, y así sucesivamente. Para eliminar información redundante se aplica el operador de diezmado en cada iteración [6]. La síntesis de la señal puede hacerse a partir de los coeficientes obtenidos mediante la DWT. La reconstrucción de los coeficientes de escala fina de la señal original puede hacerse a partir de la combinación de los coeficientes de la función de escala y de onduleta de la resolución menos fina.